



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA CIVIL

**EVALUACIÓN Y POST-PROCESAMIENTO DE PRONÓSTICOS
CLIMÁTICOS EN LA CORDILLERA DE LOS ANDES DE CHILE CENTRAL
(27°S - 37°S)**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL

FELIPE CRISTIAN TOLEDO PALMA

PROFESOR GUÍA:
James McPhee Torres

PROFESOR CO-GUÍA:
Pablo Mendoza Zúñiga

COMISIÓN:
Francisco Jara Álvarez

SANTIAGO DE CHILE
2023

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE INGENIERO CIVIL
POR: FELIPE CRISTIAN TOLEDO PALMA
FECHA: 2023
PROF. GUÍA: JAMES PETER MCPHEE TORRES

EVALUACIÓN Y POST-PROCESAMIENTO DE PRONÓSTICOS CLIMÁTICOS EN LA CORDILLERA DE LOS ANDES DE CHILE CENTRAL (27°S - 37°S)

Este estudio evalúa la calidad del producto de pronósticos climáticos SEAS5 crudos y corregidos, de precipitación y temperatura, desarrollado por el Centro Europeo de Pronósticos Climáticos de Mediano Plazo. El estudio se enfoca en Chile central entre las latitudes 27°S-37°S, donde los pronósticos climáticos toman mayor relevancia debido a la sequía que afecta a la zona.

Los métodos de post-procesamiento para la corrección de los pronósticos utilizados son el Escalamiento Lineal (LS) y el Mapeo de Cuantiles (QM), mientras que la evaluación de los pronósticos se realiza a escala mensual y trimestral mediante cuatro métricas de verificación: Sesgo, RMSE, R^2 y CRPSS, las cuales se utilizan para medir la calidad de los pronósticos.

Dentro de los principales resultados, se obtuvo que el producto crudo de temperatura tiene un sesgo frío en la cordillera de los Andes marcado en las estaciones del año de menores temperaturas, mientras que el producto crudo de precipitación presenta un sesgo porcentual húmedo en la zona norte (27°S-30°S) que se acentúa en las estaciones del año de mayores temperaturas. Tras el post-procesamiento, ambos métodos anulan efectivamente el sesgo de los productos de precipitación y temperatura. En cuanto a la precisión del pronóstico, el producto de temperatura mejora significativamente tras el post-procesamiento, mientras que el producto de precipitación no presenta mejoras significativas. Respecto a la coherencia de los pronósticos, el producto crudo temperatura no garantiza coherencia (es decir, no tienen valor agregado respecto a la climatología), mientras que el producto de precipitación garantiza coherencia para tiempos de adelanto iguales a un mes. Tras de aplicar los métodos de corrección, el producto de temperatura garantiza coherencia para tiempos de adelanto de un mes, mientras que la precipitación garantiza coherencia la mayor parte del tiempo.

En conclusión, el producto de temperatura tiene mejores rendimientos luego de aplicar los métodos de post-procesamiento que el producto de precipitación, por lo que queda propuesto para estudios futuros la investigación de diferentes técnicas de post-procesamiento que corrijan de manera efectiva los pronósticos de precipitación. Por último, queda propuesto también evaluar diversos productos de pronósticos climáticos con el fin de ampliar el conocimiento sobre la gestión hídrica en el territorio nacional.

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Objetivos	2
2. Revisión de Antecedentes	3
2.1. Pronósticos climáticos globales	3
2.2. Pronósticos climáticos SEAS5	3
2.3. Evaluación de pronósticos	4
2.3.1. Calidad de los pronósticos	4
2.3.2. Métricas de verificación	5
2.4. Post procesamiento	6
3. Zona de Estudio y Datos	8
3.1. Antecedentes generales	8
3.2. Datos de Verificación	9
3.3. Datos de Pronósticos	10
4. Metodología	11
4.1. Compatibilización de datos	11
4.1.1. Resolución horizontal	11
4.1.2. Miembros del conjunto	11
4.2. Post-procesamiento	12
4.2.0.1. Escalamiento Lineal (LS)	12
4.2.0.2. Mapeo de Cuantiles (QM)	12
4.3. Evaluación de pronósticos	13
4.3.1. Sesgo	14
4.3.2. Raíz del Error Cuadrático Medio (RMSE)	14
4.3.3. Coeficiente de Determinación (R^2)	14
4.3.4. Habilidad de puntuación de probabilidad clasificada continua (CRPSS)	15
5. Resultados	16
5.1. Temperatura	16
5.1.1. Sesgo	17
5.1.2. Raíz del Error Cuadrático Medio (RMSE)	19
5.1.3. Coeficiente de Determinación (R^2)	21
5.1.4. Habilidad de puntuación de probabilidad clasificada continua (CRPSS)	23
5.2. Precipitación	26
5.2.1. Sesgo	27

5.2.2.	Raíz del Error Cuadrático Medio Normalizado	29
5.2.3.	Coefficiente de Determinación (R^2)	31
5.2.4.	Habilidad de puntuación de probabilidad clasificada continua (CRPSS)	33
6.	Discusión	37
6.1.	Temperatura	37
6.2.	Precipitación	38
6.3.	Post-procesamiento	40
7.	Conclusiones	41
8.	Bibliografía	43
	ANEXOS	48
	Anexo A. Dispersión de datos de Temperatura	48
	Anexo B. Dispersión de datos de Precipitación	53

Índice de Tablas

5.1.	Celdas con valores máximos y mínimos de sesgo trimestral de temperatura. . .	17
5.2.	Celdas con valores máximos y mínimos de RMSE trimestral de temperatura. .	19
5.3.	Celdas con valores máximos y mínimos de R^2 trimestral de temperatura. . . .	21
5.4.	Celdas con valores máximos y mínimos de CRPSS trimestral de temperatura. .	25
5.5.	Número de celdas con CRPSS positivo para los valores trimestrales de temperatura, utilizando como referencia la climatología.	26
5.6.	Número de celdas con CRPSS positivo para los valores trimestrales de temperatura, utilizando como referencia los pronósticos crudos.	26
5.7.	Celdas con valores máximos y mínimos de sesgo porcentual trimestral de precipitación.	27
5.8.	Celdas con valores máximos y mínimos de NRMSE porcentual trimestral de precipitación.	29
5.9.	Celdas con valores máximos y mínimos de R^2 trimestral de precipitación. . . .	31
5.10.	Celdas con valores máximos y mínimos de CRPSS trimestral de precipitación, utilizando como referencia la climatología.	35
5.11.	Número de celdas con CRPSS positivo para los valores trimestrales de precipitación, utilizando como referencia la climatología.	36
5.12.	Número de celdas con CRPSS positivo para los valores trimestrales de precipitación, utilizando como referencia los pronósticos crudos.	36

Índice de Ilustraciones

2.1.	Atributos de calidad de pronósticos que mide cada métrica de verificación (Adaptado de Huang y Zhao 2022).	5
2.2.	Clasificación de métricas de verificación (Adaptado de Huang y Zhao 2022). . .	6
2.3.	Metodología de Mapeo de Cuantiles (Adaptado de Switanek et al. 2017). . . .	7
3.1.	a) Celdas del producto de pronósticos (líneas negras) junto con las celdas del producto Cr2Met (azul) y b) mapa de elevación digital en la zona de estudio. .	8
3.2.	Datos de temperatura media trimestral promedio para cada celda de la zona de estudio.	9
3.3.	Datos de precipitación acumulada trimestral promedio para cada celda de la zona de estudio.	10
4.1.	Representación gráfica del ajuste de la grilla del CR2met a la del SEAS5 (Adaptado de Horgue et al. 2015).	11
5.1.	Gráficos de dispersión de la temperatura media mensual de los pronósticos crudos y corregidos con los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. . .	16
5.2.	Sesgo de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto. .	17
5.3.	Sesgo de los pronósticos de temperatura media trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	18
5.4.	RMSE de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto. .	19
5.5.	RMSE de los pronósticos de temperatura media trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	20
5.6.	R^2 de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto. . .	21
5.7.	R^2 de los pronósticos de temperatura media trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	22

5.8.	CRPSS de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.	23
5.9.	CRPSS de los valores trimestrales de temperatura de los pronósticos crudos, utilizando como referencia la climatología, para cada celda de la zona de estudio.	24
5.10.	CRPSS de los valores trimestrales de temperatura de los pronósticos LS, utilizando como referencia los pronósticos crudos, para cada celda de la zona de estudio.	25
5.11.	Gráficos de dispersión de la precipitación acumulada mensual de los pronósticos crudos y corregidos con los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	26
5.12.	Sesgo porcentual de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.	27
5.13.	Sesgo porcentual de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	28
5.14.	NRMSE de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.	29
5.15.	NRMSE de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	30
5.16.	R^2 de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.	31
5.17.	R^2 de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	32
5.18.	CRPSS de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.	33
5.19.	CRPSS, con la climatología como referencia, de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	34

5.20.	CRPSS, con los pronósticos crudos como referencia, de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.	35
6.1.	Mapa de dispersión del pronóstico de precipitación junto con un histograma de frecuencia.	39
A.1.	Gráficos de dispersión de los pronósticos mensuales de temperatura de todas las celdas en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos del primer mes de adelanto.	48
A.2.	Gráficos de dispersión del pronóstico crudo de temperatura del trimestre EFM, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos	49
A.3.	Gráficos de dispersión del pronóstico crudo de temperatura del trimestre AMJ, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.	50
A.4.	Gráficos de dispersión del pronóstico crudo de temperatura del trimestre JAS, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.	51
A.5.	Gráficos de dispersión del pronóstico crudo de temperatura del trimestre OND, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.	52
B.1.	Gráficos de dispersión de los pronósticos mensuales de precipitación de todas las celdas en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos del primer mes de adelanto.	53
B.2.	Gráficos de dispersión del pronóstico crudo de precipitación del trimestre EFM, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.	54
B.3.	Gráficos de dispersión del pronóstico crudo de precipitación del trimestre AMJ, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.	55
B.4.	Gráficos de dispersión del pronóstico crudo de precipitación del trimestre JAS, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.	56
B.5.	Gráficos de dispersión del pronóstico crudo de precipitación del trimestre OND, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.	57

Capítulo 1

Introducción

1.1. Motivación

La megasequía que afecta la zona central de Chile desde 2010 (Garreaud et al., 2020), provocada por un déficit de precipitación en la zona, plantea diferentes problemáticas sobre la disponibilidad del agua. Estas problemáticas afectan principalmente al consumo humano y a los sectores productivos del país, como la agricultura y minería. Adicionalmente, diversos estudios (Vargas et al., 2017; Garreaud et al., 2020) proyectan un aumento de las temperaturas y una disminución de las precipitaciones en el futuro. Frente a estas variaciones, es necesario llevar a cabo estudios sobre el comportamiento meteorológico y climático para gestionar de manera más eficiente la escasez de recursos hídricos.

En este contexto, se ha incrementado el uso de pronósticos climáticos en distintos sectores de la gestión hídrica (Weisheimer y Palmer, 2014). La necesidad de pronósticos hidroclimáticos estacionales para la gestión de los recursos hídricos ha motivado históricamente a climatólogos, hidrólogos, agencias de pronósticos y administradores del agua al desarrollo e implementación de técnicas innovadoras, como el uso de mapas de probabilidad o probabilidades conjuntas, con el objetivo de mejorar la calidad de los pronósticos (Mendoza et al., 2014).

Existen distintas instituciones que desarrollan pronósticos climáticos, de las cuales destacan dos: el Centro Europeo de Pronósticos de Mediano Plazo (ECMWF), el cual es considerado líder en la generación de pronósticos climáticos (Weisheimer and Palmer, 2014) su producto más reciente es el SEAS5 (Johnson et al., 2019), y los Centros Nacionales de Predicción Ambiental (NCEP), en Estados Unidos, con su producto más reciente CFSv2 (Saha et al. 2014).

A pesar de los avances en los sistemas de observación, los pronósticos climáticos aún presentan errores sistemáticos y aleatorios debido al conocimiento limitado sobre las condiciones iniciales y de borde de los modelos, junto a una representación imperfecta de los procesos (Huang y Zhao, 2022). Es por ello que existen diversos estudios que analizan la corrección de pronósticos climáticos, los cuales buscan mejorar la calidad de los pronósticos según las condiciones locales de los distintos territorios alrededor del mundo (e.g., Crochemore et al. 2016; Lucatero et al. 2018; Zhao et al. 2017 y Baker et al. 2018). En este contexto, la calidad de los pronósticos se mide mediante métricas de verificación a través de atributos, tales como, el sesgo, la precisión, la habilidad, la asociación, entre otros (Huang y Zhao, 2022).

Este trabajo de título busca analizar y mejorar el desempeño del producto de pronósticos de precipitación y temperatura diarias SEAS5 en Chile central (27°S-37°S) utilizando como set de datos verificación el producto grillado de precipitación y temperatura diarias CR2Met 2.0 (Boisier et al., 2018). Se realiza el post procesamiento a partir de dos métodos de corrección de sesgo: Escalamiento Linal (LS) y Mapeo de Cuantiles (QM), y se evalúa la calidad de los pronósticos climáticos crudos y corregidos mediante cuatro métricas de verificación: el Sesgo, la Raíz del error cuadrático medio (RMSE), el Coeficiente de determinación (R^2) y la Habilidad del Puntaje de Probabilidad de Rango Continuo (CRPSS, por sus siglas en inglés).

1.2. Objetivos

El objetivo principal de este trabajo es analizar la calidad de los pronósticos crudos y corregidos de precipitación y temperatura en Chile central, en el periodo 1993-2016.

Los objetivos específicos del trabajo son:

1. Mejorar la calidad de los pronósticos crudos mediante métodos de corrección de sesgo.
2. Evaluar y comparar los pronósticos crudos y corregidos mediante métricas de verificación.
3. Identificar patrones espaciales, temporales y climáticos del comportamiento de los pronósticos crudos y corregidos.

Capítulo 2

Revisión de Antecedentes

2.1. Pronósticos climáticos globales

Durante las últimas décadas, los pronósticos meteorológicos a escala global han cobrado gran relevancia debido a la utilidad de conocer las condiciones meteorológicas futuras en distintos ámbitos tales como: agricultura, medio ambiente, seguridad, entre otros. Esto cobra aún más relevancia a causa de los cambios en el clima a escala global y local (Garreaud et al., 2020; IPCC, 2020).

Actualmente, destacan dos productos de pronósticos climáticos: System 5 (SEAS5) (Johnson et al., 2019), el producto más reciente elaborado por el Centro Europeo de Pronósticos de Mediano Plazo (ECMWF), y el producto CFS en su segunda versión (Saha et al. 2014), generado por los Centros Nacionales para la Predicción Ambiental (NCEP). Otros ejemplos de pronósticos estacionales operativos incluyen los generados por Oficina Met en el Reino Unido (Maclachlan et al., 2015), el Departamento Australiano de Meteorología (BOM, por sus siglas en inglés) (Hudson et al., 2013), el Centro Climático de Beijing (Liu et al., 2015) y el Centro Hidrometeorológico de Rusia (Tolstykh et al., 2014).

2.2. Pronósticos climáticos SEAS5

En este estudio se utiliza el sistema de pronósticos estacionales SEAS5 del ECMWF, el cual se genera mediante modelos numéricos que resuelven un conjunto de ecuaciones de hidrodinámica que describen el comportamiento de la atmósfera y el océano. El sistema de pronósticos es actualizado cada cinco años aproximadamente, siendo SEAS5 el producto más reciente y se encuentra operacional desde el año 2017, reemplazando a su predecesor System 4 (SEAS4) (Molteni et al., 2011). Las mejoras en el sistema son principalmente en la generación de condiciones iniciales, la inclusión de las versiones actualizadas de los modelos atmosféricos y oceánicos y la inclusión de un modelo de pronóstico de hielo marino (Johnson et al., 2019).

El sistema de pronósticos consiste en un conjunto de 51 miembros, los cuales se generan variando la condición inicial de entrada de los modelos y se inicializan el primer día de cada mes a las 00 UTC con un horizonte de 7 meses. Adicionalmente, en los meses de Febrero, Mayo, Agosto y Noviembre, 15 de los 51 miembros tienen un horizonte suplementario de 6

meses, con una extensión total de 13 meses. SEAS5 contiene pronósticos de diversas variables atmosféricas y oceánicas con resolución horizontal de 1° y con resolución temporal diaria o intra-diaria, dependiendo de la variable. Para la verificación y calibración del sistema de pronósticos, SEAS5 utiliza un set de pronósticos retrospectivos durante el periodo 1981-2016 que pueden ser comparados con datos históricos de la variable que en estudio, el que consiste en un conjunto de 25 miembros que se inicializan el primer día de cada mes a las 00 UTC con un horizonte de 7 meses. Al igual que con los pronósticos operativos, 15 de los 25 miembros tienen un horizonte suplementario de 6 meses, con una extensión total de 13 meses.

2.3. Evaluación de pronósticos

La afirmación sobre si un pronóstico es “bueno” o “malo” era comúnmente escuchado en estudios sobre pronósticos climáticos, donde raramente se explicaba en que términos se evaluaba la calidad de estos. Por ejemplo, para los pronosticadores un “buen pronóstico” se refería a su semejanza con la observación, mientras que para los usuarios se refería a los beneficios que estos podían traer a la toma de decisiones (Murphy, 1993). En este contexto, Murphy (1993) identifica tres formas en que un pronóstico puede ser “bueno”: consistencia, que se refiere a la confianza en el criterio del pronosticador basado en sus conocimientos científicos; calidad, que refiere al grado de correspondencia entre los pronósticos y observación; y valor, que refiere a si el usuario de pronóstico aumenta sus beneficios al adherir éstos a su toma de decisiones. Debido a que tanto la “consistencia” como el “valor” tienen un carácter subjetivo, este estudio se centra en la “calidad” para evaluar el desempeño de los pronósticos.

2.3.1. Calidad de los pronósticos

Existen distintos atributos para evaluar el desempeño de los pronósticos que ayudan a caracterizar la calidad de éstos. A continuación se presentan algunos de los atributos comúnmente utilizados para la evaluación de pronósticos (Murphy, 1993; Bradley et al., 2019; Huang y Zhao, 2022).

1. Sesgo (Bias): Corresponde a la diferencia entre el promedio de los pronósticos y la observación. Describe si el pronóstico sobrestima o subestima sistemáticamente la observación.
2. Precisión (Accuracy): Corresponde al promedio de la diferencia entre los pronósticos y la observación. Describe la cercanía entre los pronósticos y la observación.
3. Asociación (Association): Corresponde a la correlación entre los pronósticos y la observación.
4. Habilidad (Skill): Corresponde a la precisión de los pronósticos frente a un pronóstico o punto de referencia. Generalmente, se utiliza la climatología como punto de referencia.
5. Confianza (Reliability): Describe qué tan bien las probabilidades pronosticadas corresponden a las frecuencias relativas observadas.
6. Resolución (Resolution): Evalúa la diferencia entre todos los miembros del pronóstico emitidos. Cuando los miembros del conjunto de pronósticos pueden predecir los diferentes escenarios posibles, el pronóstico tiene resolución.

7. Agudeza (Sharpness): Corresponde al grado de variabilidad del pronóstico y su capacidad de predecir eventos extremos.
8. Discriminación (Discrimination): Se refiere a si el pronóstico tiende a predecir algún evento en específico sobre otros.
9. Coherencia (Coherence): Se refiere a si el pronóstico es, al menos, más hábil que la climatología.

2.3.2. Métricas de verificación

Para evaluar la calidad de los pronósticos existen múltiples métricas de verificación, las cuales se dividen en tres grupos: probabilísticas, determinísticas y categóricas (Huang y Zhao, 2022). Las métricas probabilísticas se utilizan cuando los pronósticos no son un valor único, si no que miembros de un conjunto. Las métricas más populares son: CRPS (Hersbach, 2000), CRPSS (Pappenberger et al., 2015), PIT value (Gneiting et al., 2007), entre otras. Las métricas determinísticas se pueden aplicar tanto en pronósticos de valor único, como miembros de un conjunto. En este último caso se puede utilizar la media o la mediana de los conjuntos para asemejar el pronóstico a un enfoque determinístico. Dentro de las métricas determinísticas más populares se encuentran: RMSE, RMSESS, PCC, Sesgo, MAE, entre otras. Por último, las métricas con enfoque categórico miden la ocurrencia de algún evento de interés, como crecidas o sequías. Algunas de las métricas utilizadas son: Puntuación de Brier (BS, por sus siglas en inglés) (Brier, 1950), Puntuación de habilidad de la característica operativa del receptor (ROCSS, por sus siglas en inglés) (Mason y Graham, 2002), entre otras. En las Figuras 2.1 y 2.2, se presenta un gráfico donde se muestra los atributos de calidad que mide cada métrica de verificación mencionada anteriormente y su clasificación, respectivamente.




Figura 2.1: Atributos de calidad de pronósticos que mide cada métrica de verificación (Adaptado de Huang y Zhao 2022).

Pronóstico	Métrica
Probabilístico	<i>CRPS</i> <i>CRPSS</i> <i>PIT</i>
Determinístico	<i>RB</i> <i>PCC</i> <i>RMSE</i> <i>RMSESS</i> <i>MAE</i>
Categorico	<i>BS</i> <i>BSS</i> <i>ROCSS</i>

Figura 2.2: Clasificación de métricas de verificación (Adaptado de Huang y Zhao 2022).

2.4. Post procesamiento

Los pronósticos climáticos, por sí solos, no son una herramienta confiable para la predicción de variables meteorológicas (Weisheimer y Palmer, 2014). Es por esto que crece el interés en estudiar distintos métodos de post procesamiento para mejorar el desempeño de los pronósticos climáticos crudos. El post procesamiento refiere a cualquier método que genere mejoras en el desempeño de los pronósticos (Lucatero et al., 2018). Cabe señalar que en algunos estudios, el procesamiento de datos meteorológicos se dice pre procesamiento.

Existen distintos tipos de post procesamiento que van desde escalamientos simples a métodos sofisticados que incluyen mapas de probabilidades (Teutschbein y Seibert, 2012). Entre estos métodos se encuentra el Escalamiento Lineal (LS) y el Mapeo de Cuantiles (QM), los cuales se utilizan en el post procesamiento de este estudio. El método LS consiste en corregir el sesgo asumiendo que los pronósticos y la observación se igualaran en los promedios mensuales tras aplicar un factor de corrección (Teutschbein y Seibert 2012), mientras que el método QM consiste en igualar las curvas de distribución acumulada (CDF) de los pronósticos y observación (Madadgar et al., 2014), como se muestra en la Figura 2.3.

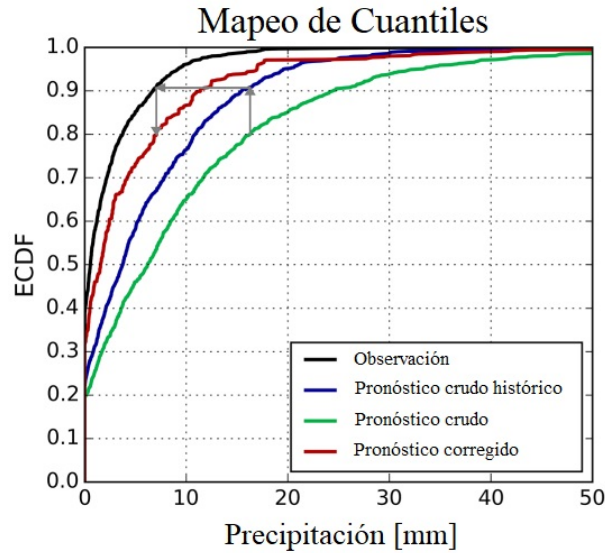


Figura 2.3: Metodología de Mapeo de Cuantiles (Adaptado de Switanek et al. 2017).

Es posible encontrar en la literatura, distintos estudios donde se aplican estos métodos de post procesamiento de pronósticos climáticos. Por ejemplo, Zhao et al. (2017) corrigieron el producto de pronósticos de precipitación del modelo POAMA del BOM en Australia mediante el método QM. El método fue muy eficiente corrigiendo el sesgo pero no aseguró confianza en la dispersión del conjunto de pronósticos ni garantizó coherencia. En Australia también, Wang et al. (2019) corrigieron los productos de pronósticos de precipitación, temperatura máxima y temperatura mínima del SEAS5 del ECMWF mediante el método LS. El método no aseguró confianza en la dispersión del conjunto de pronósticos ni garantizó coherencia en algunas zonas de Australia en distintos meses del año. En la cuenca del río Limpopo en África, Watterhall et al. (2015) realizaron un estudio de sequías utilizando el producto SEAS4 del ECMWF. En este estudio definen la sequía con un valor umbral de precipitación y junto a realizar un post procesamiento con el método QM se obtienen mejoras en la habilidad del pronóstico. Crochemore et al. (2016) utilizaron el método LS para corregir el producto de precipitación del SEAS4 en algunas cuencas de Francia. Como resultado se obtuvo que el método mejoró en la agudeza y precisión del pronóstico. Y, finalmente, Lucatero et al. (2018) corrigieron el producto de precipitación y temperatura del SEAS4 en Dinamarca mediante ambos métodos. Ambos métodos corrigen eficientemente el sesgo y, en el caso de la temperatura, se obtienen leves mejoras primer mes de adelanto, mientras que para la precipitación, resultó difícil obtener mejoras significativas.

Existen otros métodos de post procesamiento en la literatura: el Mapeo de Cuantiles Delta (QDM) que, a diferencia del QM, considera el cambio climático en el factor de corrección (Switanek et al, 2016); o la Probabilidad Conjunta Bayesiana, que consiste en generar una distribución de probabilidad conjunta para caracterizar la relación entre los pronósticos crudos y la observación (Peng et al, 2014; Wang et al, 2019).

Capítulo 3

Zona de Estudio y Datos

3.1. Antecedentes generales

La región de estudio corresponde a Chile central y abarca 32 celdas de 1° latitud-longitud (aproximadamente 100 km^2) correspondiente a la resolución espacial del producto de pronósticos, comprendidas entre las latitudes 27°S - 37°S y las longitudes 69°O - 72°O . Cabe mencionar que el producto de pronósticos se encuentra disponible para todo el territorio chileno y, en particular, este estudio se hace énfasis en cuencas de montaña de régimen nival en la zona central. En la Figura 3.1 se muestra la distribución geográfica de las celdas del producto de pronósticos (1° latitud-longitud) y las celdas del producto de verificación Cr2Met ($0,05^\circ$ latitud-longitud) en el territorio chileno, junto con el modelo de elevación digital de la zona.

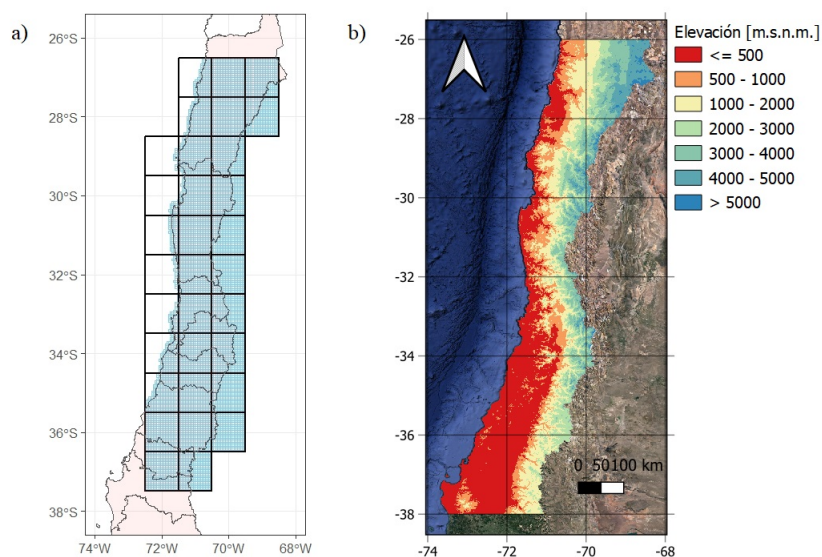


Figura 3.1: a) Celdas del producto de pronósticos (líneas negras) junto con las celdas del producto Cr2Met (azul) y b) mapa de elevación digital en la zona de estudio.

3.2. Datos de Verificación

En este estudio se utiliza el producto grillado CR2Met 2.0 (Boisier et al., 2018) como datos de verificación, el cual cuenta con información diaria de precipitación y temperatura media, máxima y mínima a lo largo y ancho del territorio chileno. Este producto posee una resolución espacial de $0,05^\circ$ latitud-longitud (5 km aproximadamente) y una resolución temporal diaria en el periodo 1979-2020. En el caso de la temperatura, el producto se generó a partir del post-procesamiento del reanálisis atmosférico ERA5 (Hersbach et al., 2020), el producto de temperatura superficial de MODIS e información local, como la topografía y observaciones en terreno, mientras que el producto de precipitación proviene del post-procesamiento del reanálisis atmosférico ERA5, basado en la topografía local y medición de estaciones. En las Figuras 3.2 y 3.3, se presentan los promedios de temperatura media trimestral y precipitación acumulada trimestral, respectivamente, del producto CR2Met 2.0. A partir de este punto, para referirse al producto de verificación CR2Met se utilizará la palabra “observación”.

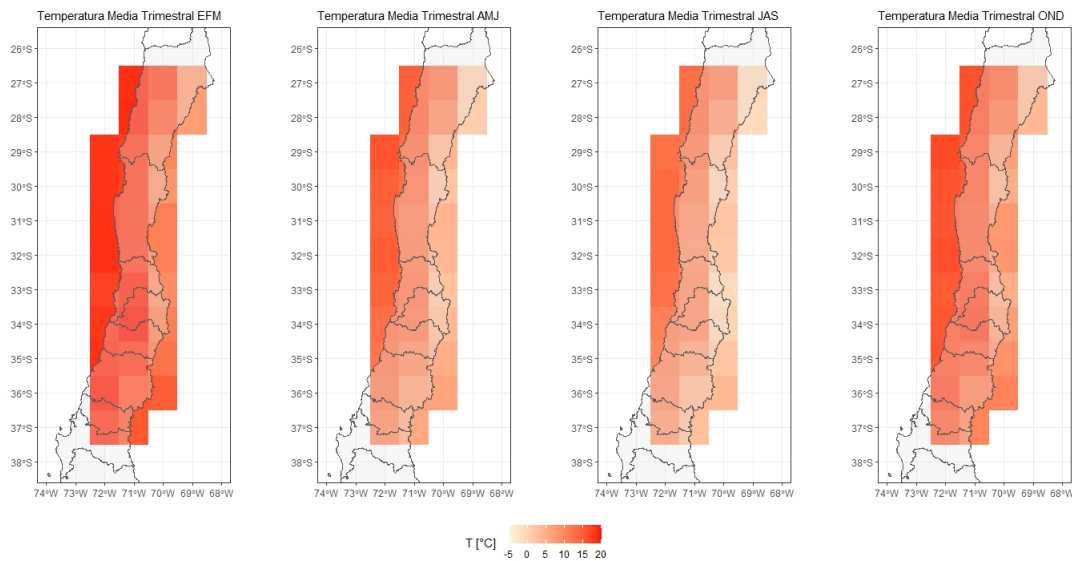


Figura 3.2: Datos de temperatura media trimestral promedio para cada celda de la zona de estudio.

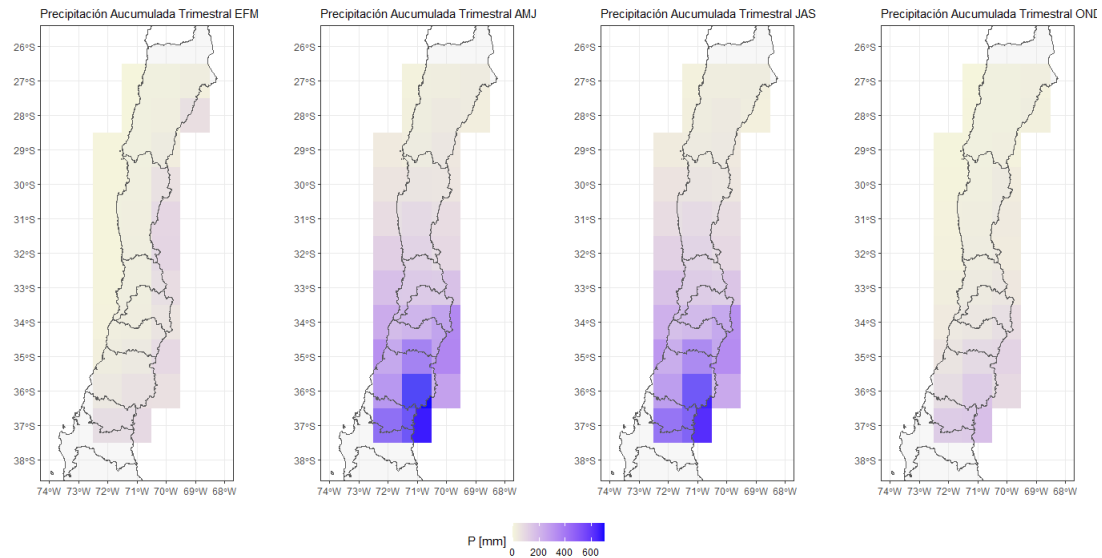


Figura 3.3: Datos de precipitación acumulada trimestral promedio para cada celda de la zona de estudio.

3.3. Datos de Pronósticos

El producto SEAS5 tiene pronósticos de diversas variables climáticas, las cuales se pueden descargar desde <https://cds.climate.copernicus.eu/cdsapp!/dataset/seasonal-original-single-levels>. Como se mencionó en capítulos anteriores, en este estudio se utilizan los pronósticos de precipitación y temperatura, los cuales se descargan en el periodo 1993-2016 (Retrospectiva), ya que no se encuentra disponible el periodo 1981-1993 de manera gratuita, y se descargan 32 celdas de 1° latitud-longitud (100 km) comprendidas en la zona de estudio. El producto de pronósticos contiene cinco dimensiones: miembros del conjunto (25), mes de emisión de pronósticos (288), latitud (11), longitud (4) y el tiempo de adelanto (215 días). En particular, el pronóstico de temperatura posee una resolución temporal intra-diaria de seis horas, mientras que el pronóstico de precipitación posee una resolución temporal diaria.

Capítulo 4

Metodología

En esta sección se detalla la metodología utilizada para (i) compatibilizar las resoluciones espaciales y temporales de los datos de observación y pronósticos, (ii) la corrección de los pronósticos mediante métodos de escalamiento lineal y por cuantiles y (iii) la evaluación de los pronósticos crudos y corregidos mediante métricas determinísticas y probabilísticas.

4.1. Compatibilización de datos

4.1.1. Resolución horizontal

Debido a la diferencia de resolución de los productos, se realiza un escalamiento espacial del producto de observación ($0,05^\circ$ latitud-longitud) a la resolución del producto de pronósticos (1° latitud-longitud), promediando todas las celdas del producto de observación que se encuentren dentro de la celda del producto de pronósticos (Figura 4.1).




Figura 4.1: Representación gráfica del ajuste de la grilla del CR2met a la del SEAS5 (Adaptado de Horgue et al. 2015).

4.1.2. Miembros del conjunto

El producto de pronósticos corresponde a un conjunto de 25 miembros, por lo que se calcula el promedio de los 25 miembros de cada día pronosticado para evaluar mediante métricas determinísticas, mientras que se utilizan todos los miembros del conjunto para evaluar los pronósticos mediante métricas probabilísticas.

4.2. Post-procesamiento

A continuación, se detalla la metodología empleada en la corrección del producto de pronósticos. Los métodos de post-procesamiento que se utilizan corresponden al Escalamiento Lineal (Teutschbein and Seibert, 2012) y el Mapeo de Cuantiles (Madadgar et al., 2014). Cabe señalar que en el caso de la precipitación, antes de aplicar los métodos de post-procesamiento, se igualan la cantidad de días secos de los meses de los pronósticos con la cantidad de días secos en los meses de observación eliminando los días de menor magnitud de precipitación del producto de pronósticos mediante un umbral que varía en cada mes y cada celda en la zona de estudio. En los casos en que la cantidad de días secos de un mes del pronóstico sean mayor o igual a la observación, no se interviene el producto. Este proceso se realiza para cada mes y celda del producto de pronósticos.

4.2.0.1. Escalamiento Lineal (LS)

El método de Escalamiento Lineal consiste en aplicar un factor de corrección a los pronósticos retrospectivos utilizando los promedios mensuales de precipitación y temperatura. Los promedios mensuales se calculan considerando todos los años en estudio excluyendo el año en que se está corrigiendo. Se considera el promedio de los miembros del conjunto de los pronósticos para el factor de corrección y se corrige cada miembro por separado. En el caso de la precipitación el factor es el cociente entre el promedio mensual de la observación y del pronóstico, como se muestra en la ecuación 4.1, mientras que en el caso de la temperatura el factor es la diferencia entre los promedios mensuales de la observación y los pronósticos, como se presenta en la ecuación 4.2.

$$p_{i,k}^* = \frac{\sum_{j=1}^{N-1} y_j}{\sum_{j=1}^{N-1} \bar{p}_j} p_{i,k} \quad (4.1)$$

$$p_{i,k}^* = p_{i,k} - \frac{1}{N-1} \left[\sum_{j=1}^{N-1} \bar{p}_j - \sum_{j=1}^{N-1} y_j \right] \quad (4.2)$$

donde $p_{i,k}$ corresponde al pronóstico, $p_{i,k}^*$ al pronóstico corregido, \bar{p}_j al promedio de los miembros del conjunto de pronósticos del mes j , y_j a la observación, i a cada mes que se corrige, k cada miembro del conjunto y N los años del periodo en estudio.

Esta metodología es válida para la corrección de pronósticos en retrospectiva. En el caso de los pronósticos actuales, la corrección mediante el método LS se realiza de manera similar, salvo que en este caso se consideran todos los datos de pronósticos en retrospectiva para calcular los factores de corrección.

4.2.0.2. Mapeo de Cuantiles (QM)

El método de Mapeo de Cuantiles consiste en igualar las curvas de distribución acumulada (CDF, por sus siglas en inglés) de los pronósticos y de la observación como se muestra en la Figura 4.3. La CDF de observación se configura utilizando los valores diarios de observación

de un mes en específico y de todos años del periodo de estudio (excluyendo el año en que se está corrigiendo). Por ejemplo, si se corrige el mes de marzo, la CDF de observación se configuraría con 31 (días) x 23 (años) valores. La CDF de pronósticos se configura de igual manera que la CDF de observación, salvo que en este caso se agregan los miembros del conjunto para generar la CDF, utilizando 31 (días) x 23 (años) x 25 (miembros) valores.

$$p_{i,k}^* = G_i^{-1}(F_i(p_{i,k})) \quad (4.3)$$

donde $p_{i,k}$ corresponde al pronóstico, $p_{i,k}^*$ al pronóstico corregido, G corresponde a la CDF de observación, F a la CDF de los pronósticos, i a cada mes que se corrige y k cada miembro del conjunto.

Como se mencionó anteriormente, esta metodología es valida para la corrección de pronósticos en retrospectiva. En el caso de los pronósticos actuales, la corrección mediante el método QM se realiza de manera similar, a diferencia que en este caso se consideran todos los datos de pronósticos en retrospectiva para configurar las CDF de pronósticos y observación.

4.3. Evaluación de pronósticos

La evaluación de los pronósticos se realiza tanto para los pronósticos crudos, como para los pronósticos post-procesados con los métodos de corrección de sesgo. Para la evaluación de los pronósticos se utilizan tres métricas determinísticas y una probabilística: sesgo, raíz del error cuadrático medio (RMSE, por sus siglas en inglés), coeficiente de determinación (R^2) y habilidad de puntuación de probabilidad clasificada continua (CRPSS, por sus siglas en ingles) (Hersbach, 2000). Las métricas se calculan según dos configuraciones de datos con el fin de realizar un análisis temporal de los pronósticos a resolución mensual sobre toda la zona de estudio en conjunto y un análisis espacial distribuido por cada celda en la zona de estudio a resolución estacional:

1. Precipitación acumulada mensual y temperatura media mensual, donde el tiempo de adelanto se agrupa en siete meses para cada mes de inicialización de pronósticos, extendidos para los 24 años del periodo 1993-2016 y en las 32 celdas pertenecientes a la zona de estudio (es decir, para cada mes de emisión (12) y cada mes de adelanto (7) se calcula la métrica en una muestra de 24 x 32 pares observación-pronóstico).
2. Precipitación acumulada trimestral y temperatura media trimestral, donde el tiempo de adelanto se agrupa en solo un trimestre (EFM, AMJ, JAS y OND), para cuatro meses de inicialización de pronósticos (enero, abril, julio y octubre), extendidos para los 24 años del periodo 1993-2016 y cada celda de la zona de estudio por separado (es decir, para cada trimestre (4) y cada celda (32) se calcula la métrica en una muestra de 24 pares observación-pronóstico)

4.3.1. Sesgo

El sesgo mide la subestimación o sobreestimación del pronóstico respecto de la observación. Se utiliza el promedio de todos los miembros del conjunto del pronóstico y, en el caso de la precipitación, se obtiene el sesgo porcentual según la ecuación 4.4, mientras que en el caso de la temperatura se calcula el sesgo mediante la ecuación 4.5.

$$SesgoPorcentual = \left(\frac{\sum_{i=1}^N \bar{p}_i}{\sum_{i=1}^N y_i} - 1 \right) \times 100 \quad (4.4)$$

$$Sesgo = \frac{1}{N} \left[\sum_{i=1}^N \bar{p}_i - \sum_{i=1}^N y_i \right] \quad (4.5)$$

donde N corresponde a los años en estudio, i al mes pronosticado dado un mes de iniciación, y_i la observación en el mes i y \bar{p}_i al promedio de los miembros del conjunto para el mes i .

4.3.2. Raiz del Error Cuadrático Medio (RMSE)

Se evalúa el RMSE, métrica que mide la precisión del pronóstico. Este valor solo entrega valores mayores a 0, siendo este el valor óptimo. En el caso de la precipitación se calcula mediante la ecuación 4.6 el RMSE normalizado por la media (NRMSE), mientras que para la temperatura se calcula el RMSE según la ecuación 4.7.

$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (\bar{p}_i - y_i)^2}}{\bar{y}} \quad (4.6)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\bar{p}_i - y_i)^2} \quad (4.7)$$

donde N , i , y_i y \bar{p}_i corresponden a los mismos valores que la ecuación 4.4.

4.3.3. Coeficiente de Determinación (R^2)

El coeficiente de determinación mide la correlación entre el pronóstico y la observación. Se obtiene, tanto para la precipitación como la temperatura, mediante la ecuación 4.8 y se obtienen valores entre 0 y 1, siendo este último valor el óptimo.

$$R^2 = \left(\frac{\sum (y_i - y_{i,prom})(\bar{p}_i - \bar{p}_{i,prom})}{\sqrt{\sum (y_i - y_{i,prom})^2 \sum (\bar{p}_i - \bar{p}_{i,prom})^2}} \right)^2 \quad (4.8)$$

donde i , y_i y \bar{p}_i corresponden a los mismos valores que la ecuación 4.4, y el sub-índice *prom* corresponde a los valores promedio de cada variable.

4.3.4. Habilidad de puntuación de probabilidad clasificada continua (CRPSS)

La puntuación de probabilidad clasificada continua (CRPS, por sus siglas en inglés) es una medida de precisión del pronóstico que considera todos los miembros del conjunto, la cual se aplica mediante la ecuación 4.9. El CRPS calcula la diferencia entre las CDF pronosticada y observada, siendo el valor óptimo el 0. Esta métrica se aplica mediante la función "EnsCrps" del paquete de R SpecsVerification (Siegert, 2015).

Finalmente, se calcula el CRPSS del pronóstico mediante la ecuación 4.11, el cual mide las mejoras que puede tener el pronóstico con respecto a una referencia. Se utiliza la climatología como modelo de referencia para calcular la habilidad del pronóstico, la cual se considera como una matriz de 12 x 24 datos, donde cada mes del año es un conjunto de 24 miembros (uno por cada año del periodo periodo de estudio 1993-2016). Además, se calcula la habilidad de los pronósticos post-procesados utilizando los pronósticos crudos como referencia. El valor óptimo de la métrica CRPSS es 1.

$$CRPS = \frac{1}{N} \sum_{i=1}^N \int_{-\infty}^{\infty} [P_i(x) - H(x - y_i)]^2 dx \quad (4.9)$$

$$H(x - y_i) = \begin{cases} 0 & \text{si } x < y_i \\ 1 & \text{si } x \geq y_i \end{cases} \quad (4.10)$$

$$CRPSS = 1 - \frac{CRPS_{pron}}{CRPS_{ref}} \quad (4.11)$$

donde P es la CDF de los miembros del conjunto del pronóstico, y_i la observación en el mes i , N los años en estudio.

Capítulo 5

Resultados

A continuación, se presentan los resultados de la evaluación de los pronósticos obtenidos a partir de las métricas de verificación mencionadas anteriormente. Cabe mencionar que se muestran dos tipos de gráficos para cada métrica: uno temporal, donde las métricas se calcularon para toda la zona de estudio en conjunto a escala mensual para cada mes de inicialización y cada mes de adelanto; y uno espacial, donde se calcularon las métricas para cada celda en específico a escala trimestral para 4 meses de inicialización (enero, abril, julio y octubre) y 1 trimestre de adelanto para cada inicialización.

5.1. Temperatura

A partir de la corrección del producto de pronósticos SEAS5 de temperatura, mediante los métodos Mapeo de Cuantiles y Escalamiento Lineal, se obtienen los resultados de la Figura 5.1. En esta Figura, se presenta un gráfico de dispersión que compara la temperatura media mensual del promedio de los miembros del conjunto de los pronósticos crudos y corregidos, para cada celda de la zona de estudio, donde se logra apreciar que ambos métodos utilizados en este informe ajustan los datos de pronósticos a la observación. Cabe destacar que por cada mes de observación existen siete pronósticos con siete tiempos de adelanto distintos. A continuación, se presentan los resultados de las distintas métricas utilizadas en este trabajo de título.

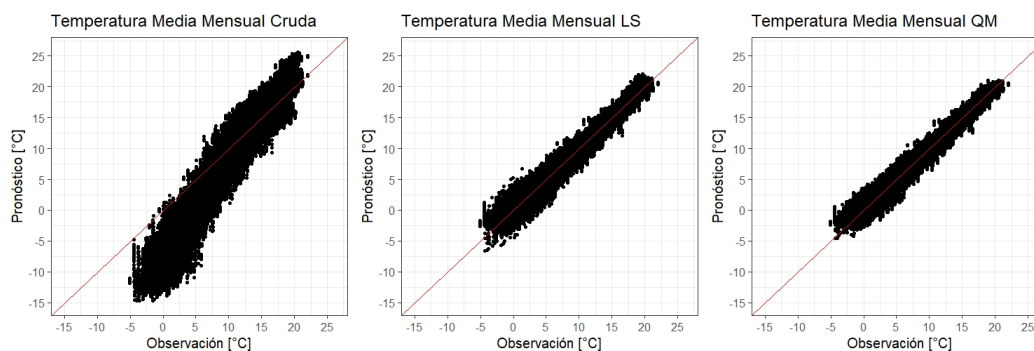


Figura 5.1: Gráficos de dispersión de la temperatura media mensual de los pronósticos crudos y corregidos con los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.1.1. Sesgo

En la Figura 5.2, se observa que los pronósticos crudos presentan un sesgo frío marcado durante todo el año exceptuando en diciembre en su segundo mes de adelanto. En los meses fríos se observa que el primer mes de adelanto es el de menor sesgo y en primavera una mayor variabilidad de sesgo entre los meses de adelanto. Sin embargo, el sesgo de los pronósticos depende mayormente del mes en estudio que del mes de adelanto. Ambos métodos de corrección eliminan eficientemente el sesgo de los pronósticos.




Figura 5.2: Sesgo de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

En la Figura 5.3, se observa que los pronósticos crudos presentan un sesgo mayormente cálido en la zona de valle, mientras que un sesgo frío en la zona cordillerana, acentuado mayormente en los trimestres de AMJ y JAS. En la Tabla 5.1, el sesgo cálido máximo es de 4,1 [°C] en el trimestre OND, mientras que el sesgo frío mínimo es de -9,7 [°C] en el trimestre JAS. En el caso del post-procesamiento de pronósticos, el sesgo alcanza valores cercanos a cero toda la zona de estudio.

Tabla 5.1: Celdas con valores máximos y mínimos de sesgo trimestral de temperatura.

Método	Máximo Sesgo [°C]				Mínimo Sesgo [°C]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	4,0	2,2	2,6	4,1	-4,2	-8,0	-9,7	-5,6
LS	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
QM	0,0	0,1	0,0	0,1	0,0	0,0	-0,1	0,0

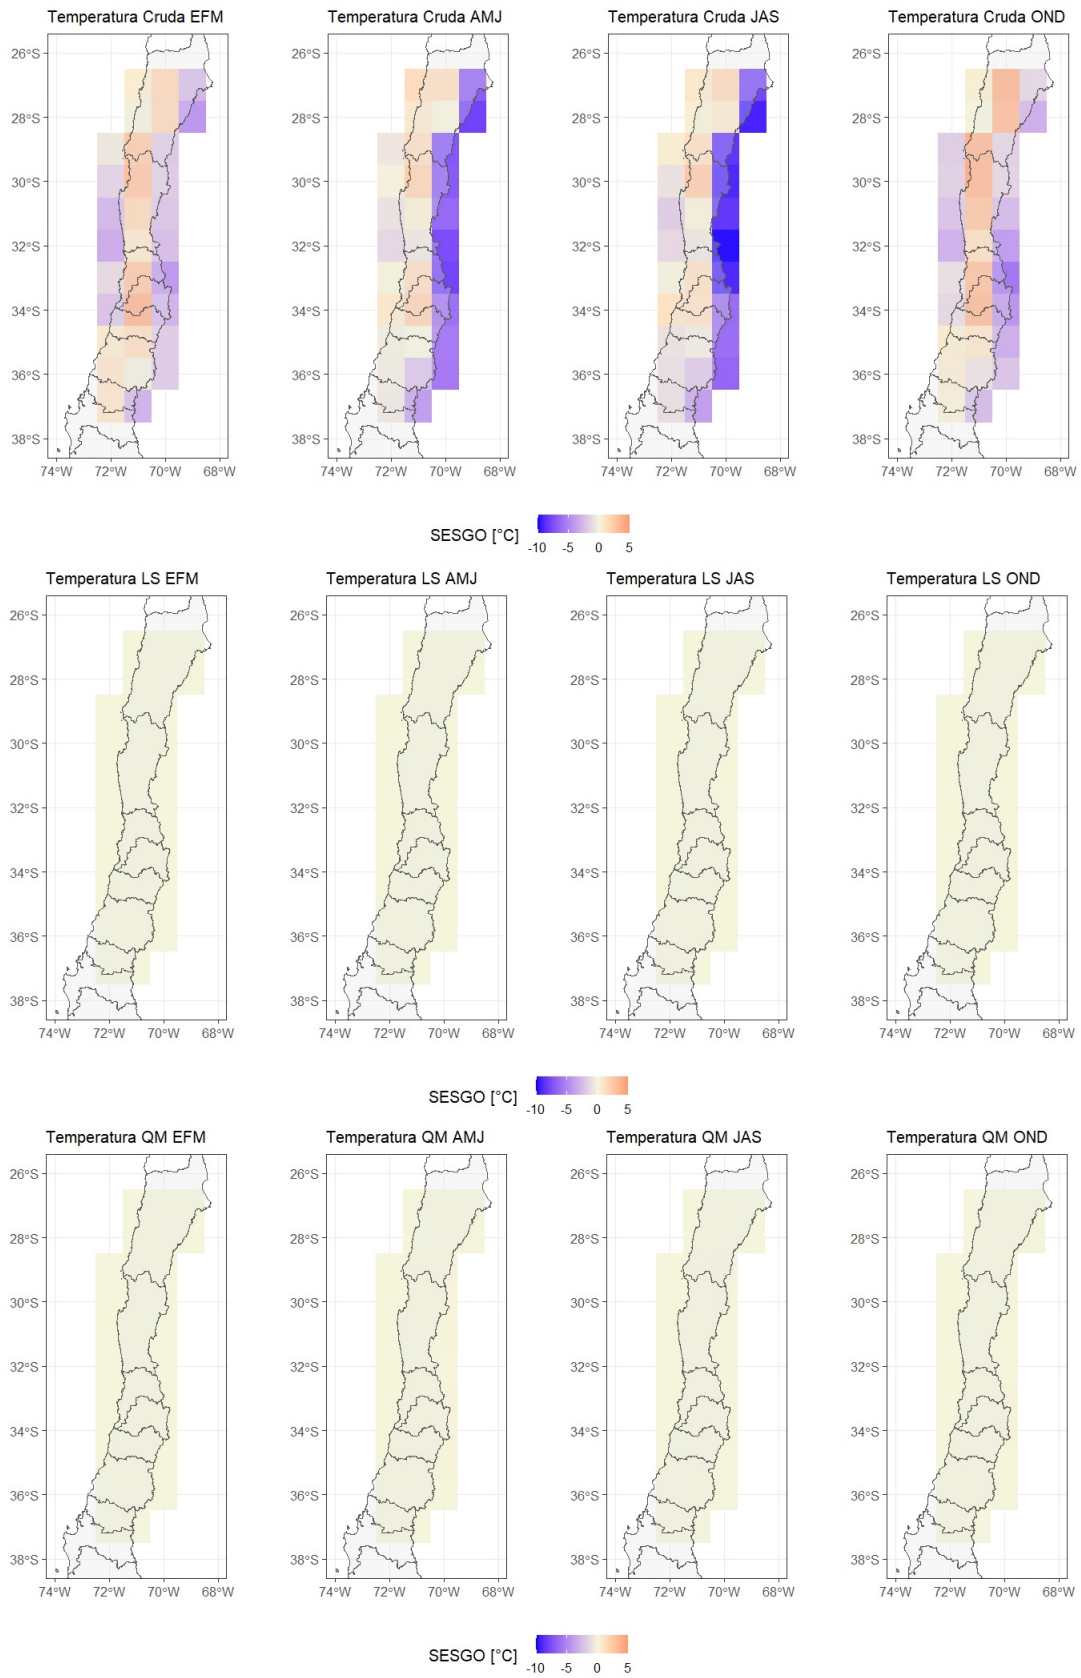


Figura 5.3: Sesgo de los pronósticos de temperatura media trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.1.2. Raíz del Error Cuadrático Medio (RMSE)

En la Figura 5.4, los pronósticos crudos presentan el menor error en el primer mes de adelanto y, al igual que en el caso anterior, en primavera se tiene mayor variabilidad del error entre los meses de adelanto. Por otro lado, el error también depende mayormente del mes en estudio que del mes de adelanto. El error disminuye al aplicar el post-procesamiento con ambos métodos, donde el primer mes de adelanto es el de mejor desempeño, exceptuando el mes de julio, y disminuye la variabilidad entre los meses de adelanto.




Figura 5.4: RMSE de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

En la Figura 5.5, los pronósticos crudos presentan mayor error en la zona cordillerana en los trimestres AMJ y JAS, mientras que disminuye en la zona del valle. En la Tabla 5.2, el máximo error es de 9,8 [°C] en el trimestre JAS, mientras que el mínimo error es de 0,4 [°C] en el trimestre de AMJ. Los pronósticos corregidos con el método LS alcanzan el error máximo de 1,7 [°C] en la zona cordillerana para el trimestre de JAS. De manera similar, los pronósticos corregidos con el método de QM alcanzan el máximo error de 1,2 [°C] en la zona cordillerana para el trimestre de JAS. Respecto al error mínimo, en la Tabla 5.2, no presenta variaciones notables al corregir los pronósticos.

Tabla 5.2: Celdas con valores máximos y mínimos de RMSE trimestral de temperatura.

Método	Máximo RMSE [°C]				Mínimo RMSE [°C]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	4,2	8,1	9,8	5,7	0,6	0,4	0,5	0,4
LS	0,7	1,1	1,7	1,1	0,4	0,4	0,3	0,3
QM	0,6	1,0	1,2	0,8	0,3	0,3	0,3	0,2

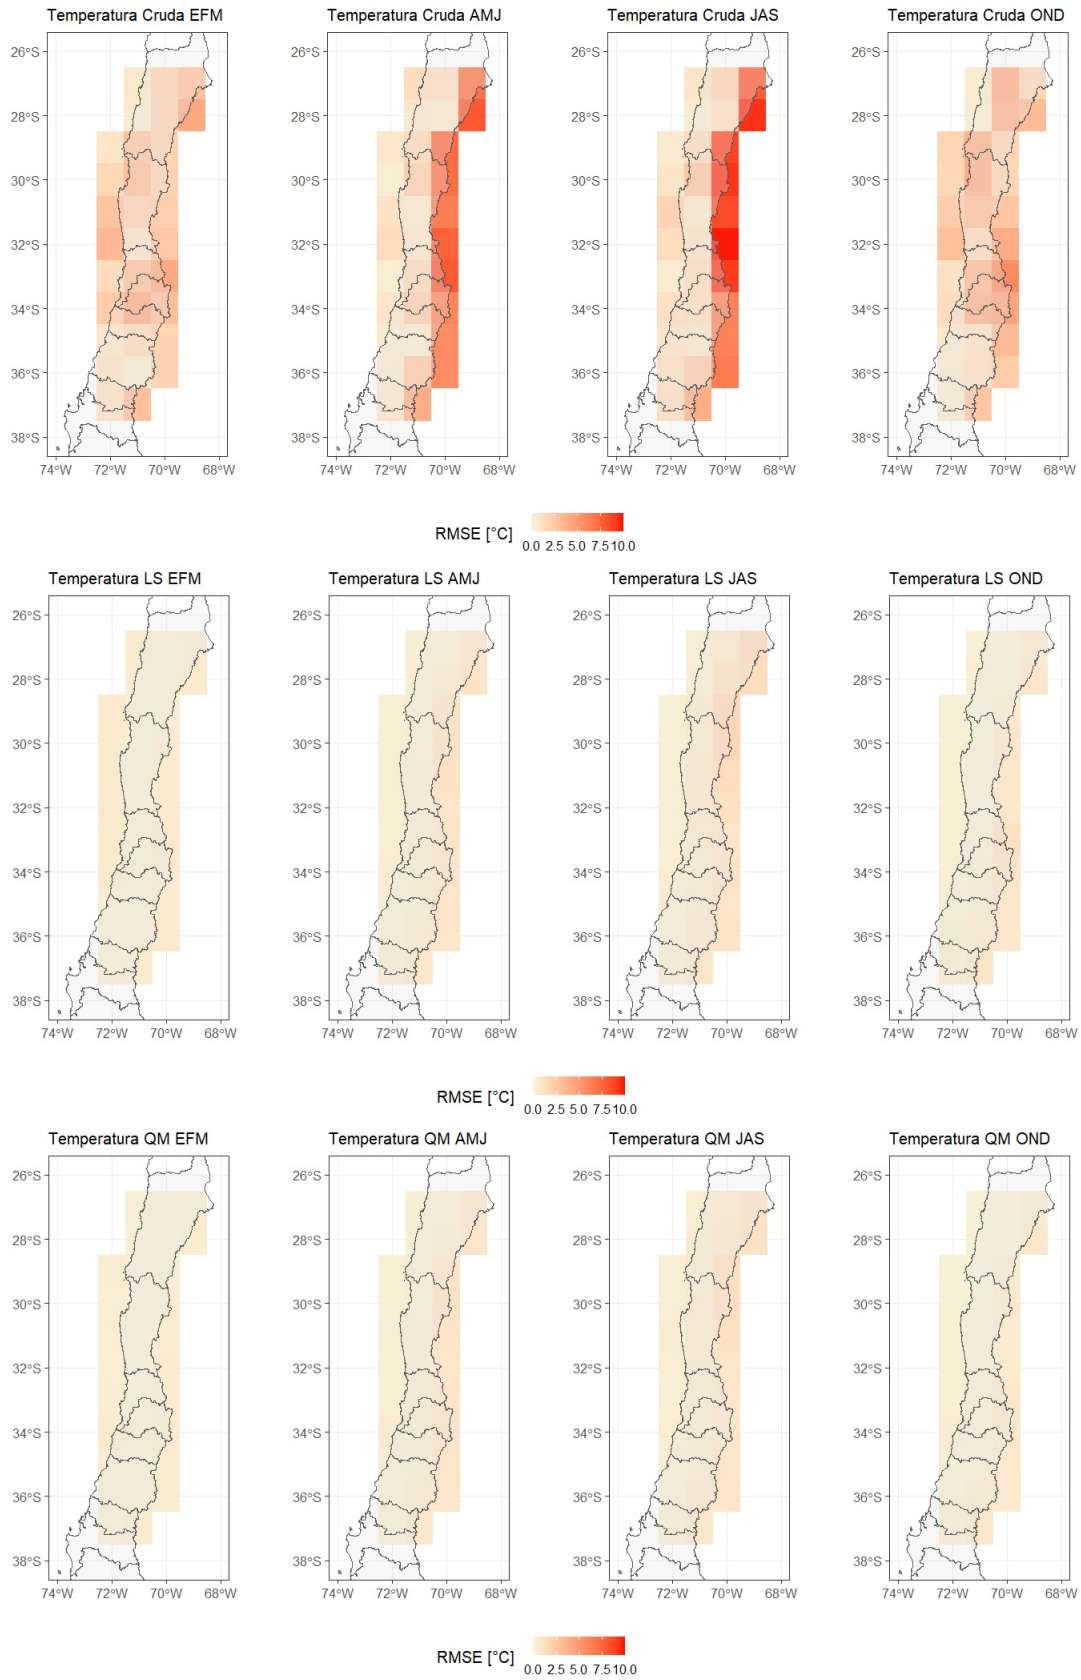


Figura 5.5: RMSE de los pronósticos de temperatura media trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.1.3. Coeficiente de Determinación (R^2)

En la Figura 5.6, se observa que el R^2 de los pronósticos crudos es cercano a 1 durante todo el año para todos los meses de adelanto. Al igual que con la métrica anterior, el primer mes de adelanto es el de mejor desempeño, exceptuando el mes de julio. No se observan variaciones significativas al aplicar los métodos de post-procesamiento.




Figura 5.6: R^2 de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

En la Figura 5.7, se obtienen mejores resultados en el trimestre de OND y peores resultados en la zona cordillerana en los trimestres de AMJ y JAS. Las diferencias entre el R^2 de los pronósticos crudos y corregidos son despreciables. En la Tabla 5.3, el máximo R^2 es de 0,7 y se observa en el trimestre OND, mientras que el mínimo R^2 es de 0 y se presenta prácticamente en todos los trimestres.

Tabla 5.3: Celdas con valores máximos y mínimos de R^2 trimestral de temperatura.

Método	Máximo R^2 [-]				Mínimo R^2 [-]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	0,6	0,6	0,5	0,7	0,1	0,0	0,0	0,1
LS	0,6	0,5	0,5	0,7	0,0	0,0	0,0	0,1
QM	0,6	0,6	0,5	0,7	0,1	0,0	0,0	0,1

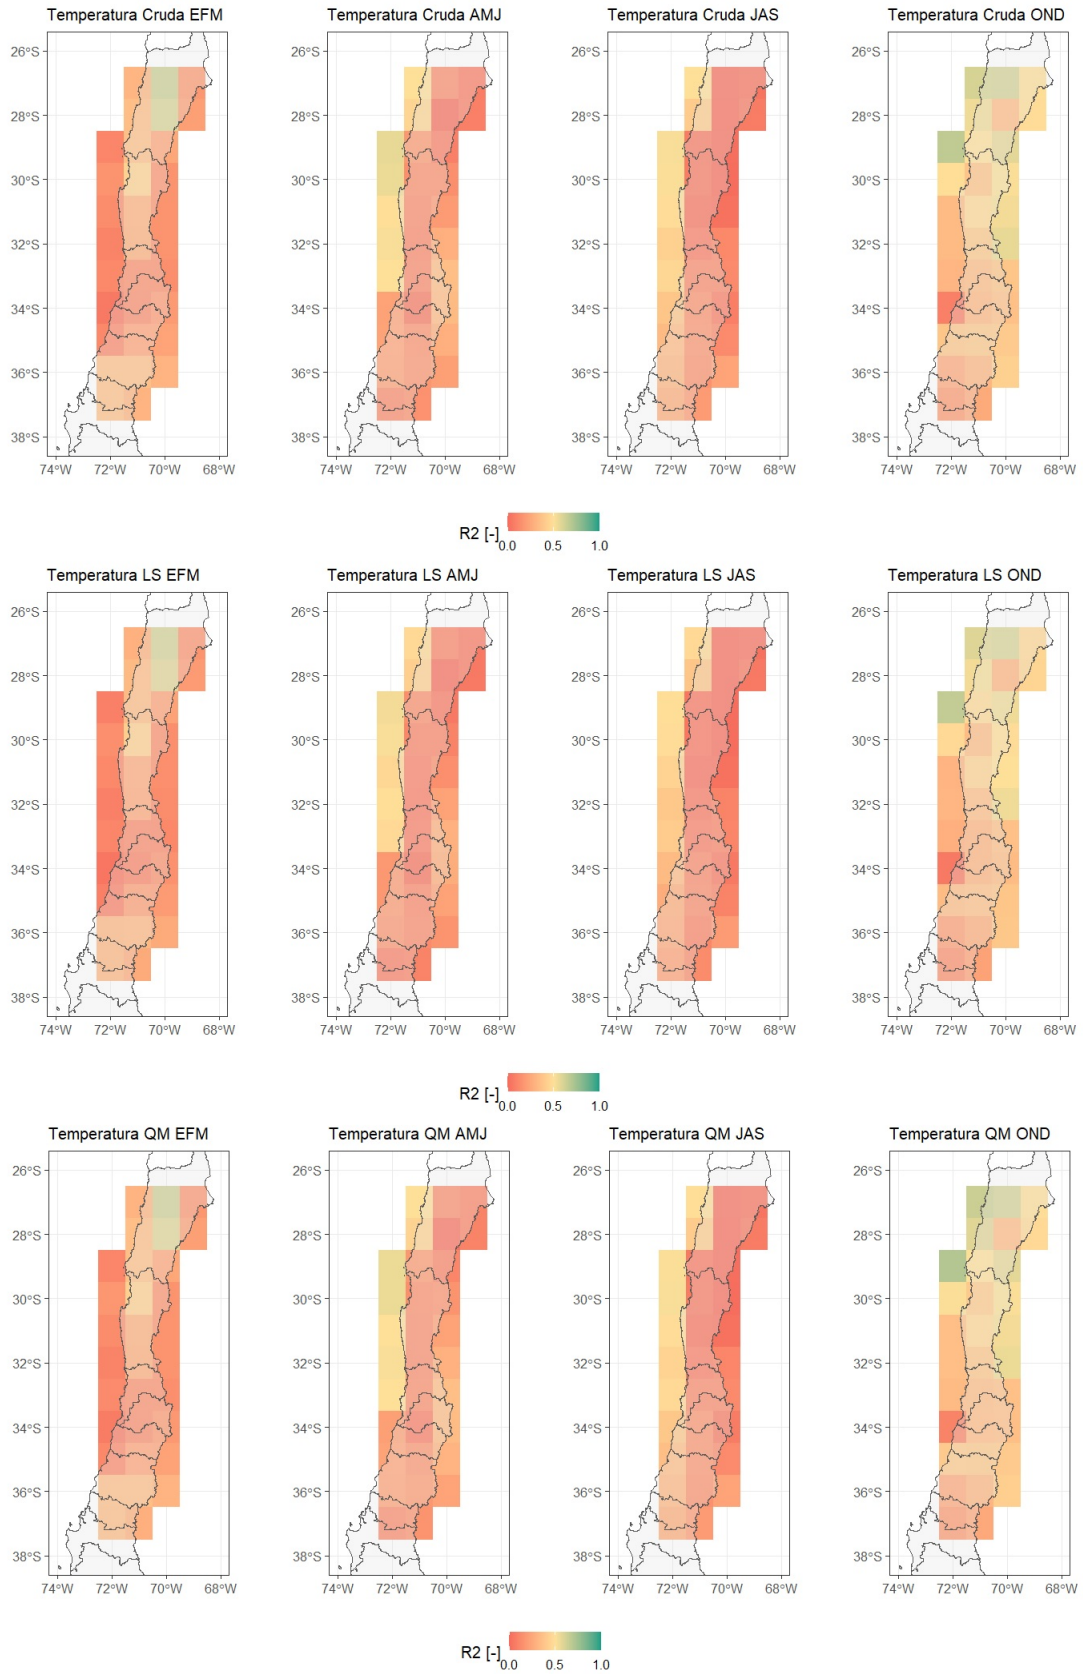


Figura 5.7: R^2 de los pronósticos de temperatura media trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.1.4. Habilidad de puntuación de probabilidad clasificada continua (CRPSS)

En la Figura 5.8, se observa una distribución mas caótica del CRPSS de los pronósticos crudos en comparación con las otras métricas presentadas anteriormente. En los meses de primavera hay mayor variabilidad entre los meses de adelanto y en los meses de invierno, el primer me de adelanto es el de mejor desempeño. Sigue dependiendo mayormente del mes en estudio que del mes de adelanto y no se obtiene ningún valor de CRPSS positivo. Al corregir los pronósticos con ambos métodos aumenta el CRPSS, teniendo, al menos, todos los primeros meses de adelanto positivos exceptuando el mes de julio.




Figura 5.8: CRPSS de los pronósticos de temperatura media mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

En la Figura 5.9, los pronósticos crudos presentan CRPSS bajos en la zona cordillerana para los trimestres AMJ y JAS y en la zona del valle norte para el trimestre de OND, mientras que en la zona del valle aumentan para estos trimestres. En la Tabla 5.4, se observa que el CRPSS mínimo se alcanza en el trimestre de OND con un valor de -19,1, mientras que el máximo lo alcanza en AMJ, con un valor de 0,2. El post-procesamiento mejora el desempeño de los pronósticos, en el caso del método LS, alcanza el valor mínimo de CRPSS de -0,9 en la zona cordillerana en el trimestre de JAS, mientras que con el método QM, se llega al mínimo de -0,7 en la zona costera del trimestre EFM. En la Tabla 5.5, se observa que ambos métodos aumentan la cantidad de celdas con CRPSS positivo, llegando a tener 25 y 26 celdas en AMJ y OND, respectivamente, con el método LS y 25 celdas en OND con el método QM. En la Figura 5.10, se observa una mejora del desempeño del pronósticos corregidos respecto a los pronósticos crudos, donde se tienen valores positivos de CRPSS, prácticamente, en toda la zona de estudio en los cuatro trimestres. En la Tabla 5.12, los pronósticos corregidos presentan, prácticamente, la totalidad de las celdas con CRPSS positivo, lo que significa que los pronósticos corregidos son más "hábiles" que los pronósticos crudos.

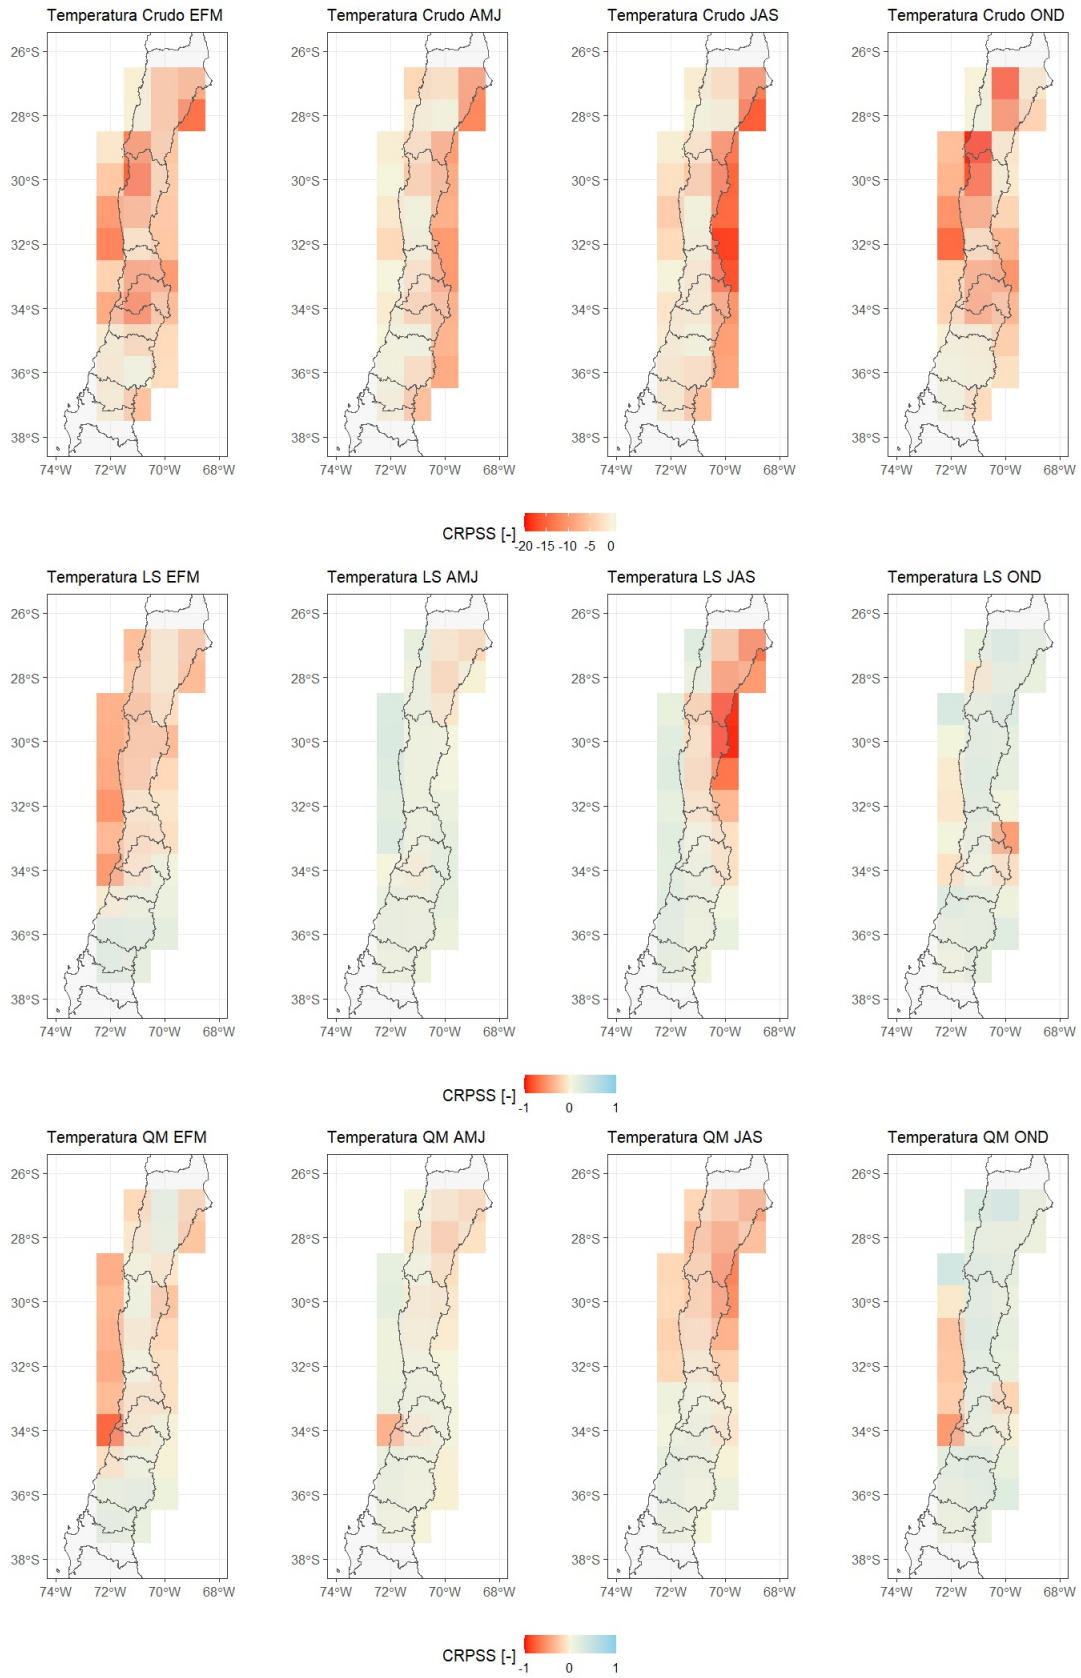


Figura 5.9: CRPSS de los valores trimestrales de temperatura de los pronósticos crudos, utilizando como referencia la climatología, para cada celda de la zona de estudio.

Tabla 5.4: Celdas con valores máximos y mínimos de CRPSS trimestral de temperatura.

Método	Máximo CRPSS [-]				Mínimo CRPSS [-]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	0,0	0,2	-0,1	0,0	-15,1	-11,7	-17,6	-19,1
LS	0,2	0,3	0,2	0,3	-0,5	-0,2	-0,9	-0,5
QM	0,2	0,2	0,2	0,4	-0,7	-0,4	-0,6	-0,5

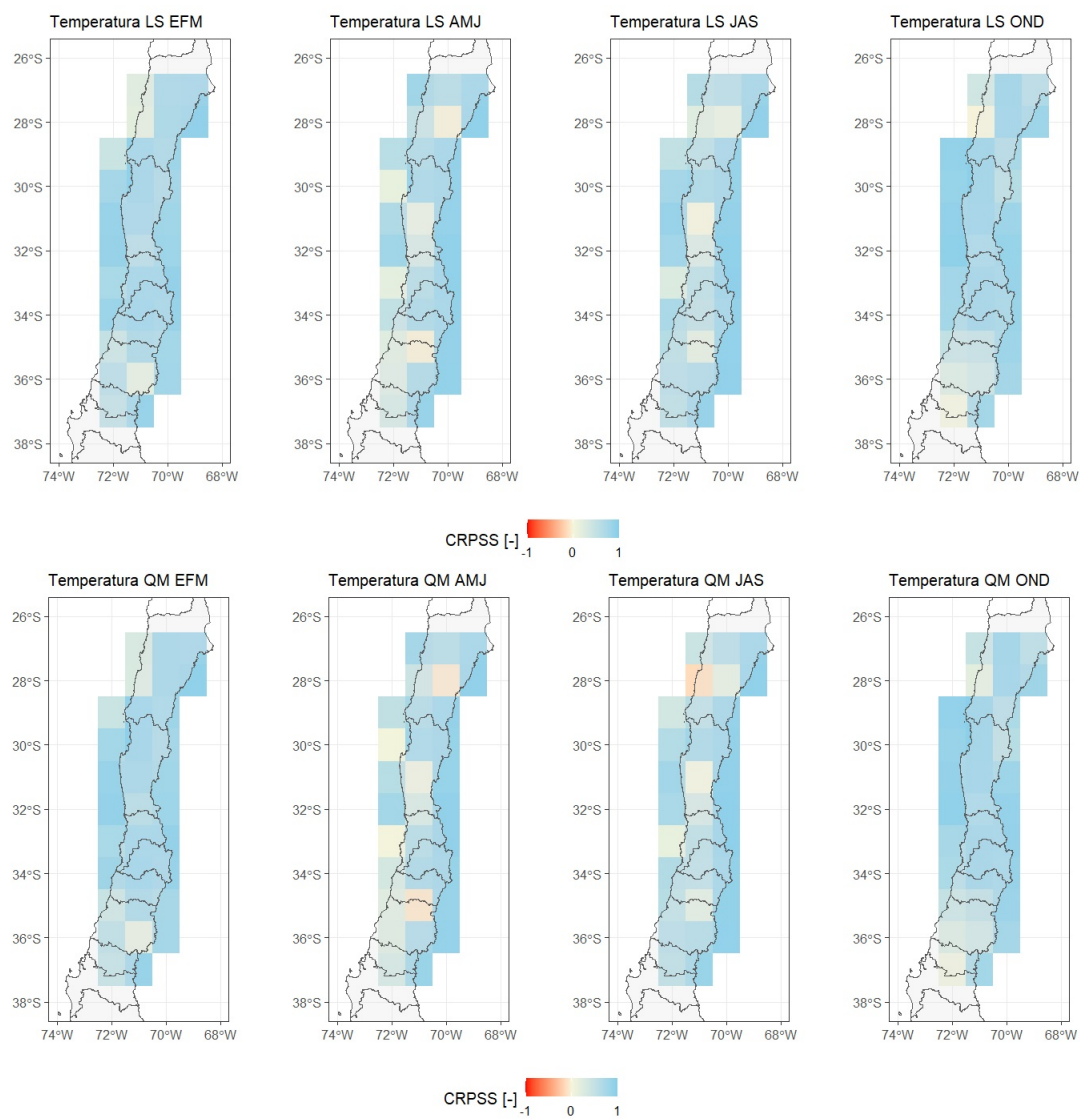


Figura 5.10: CRPSS de los valores trimestrales de temperatura de los pronósticos LS, utilizando como referencia los pronósticos crudos, para cada celda de la zona de estudio.

Tabla 5.5: Número de celdas con CRPSS positivo para los valores trimestrales de temperatura, utilizando como referencia la climatología.

Número de celdas (CRPSS > 0)				
Método	EFM	AMJ	JAS	OND
Crudo	1	3	0	1
LS	8	26	18	26
QM	9	15	11	25

Tabla 5.6: Número de celdas con CRPSS positivo para los valores trimestrales de temperatura, utilizando como referencia los pronósticos crudos.

Número de celdas (CRPSS > 0)				
Método	EFM	AMJ	JAS	OND
LS	32	30	31	31
QM	32	30	31	32

5.2. Precipitación

De manera similar a la temperatura, se obtienen los resultados del post-procesamiento mediante los métodos de corrección de sesgo del producto de pronósticos SEAS5 de precipitación. En la Figura 5.11, se presenta un gráfico de dispersión que compara la precipitación acumulada mensual del promedio de los miembros del conjunto de los pronósticos crudos y corregidos con la precipitación acumulada mensual observada, para cada celda de la zona de estudio. Se observa que el pronóstico crudo tiende a subestimar la precipitación y que la corrección de sesgo con ambos métodos corrige levemente esta condición.




Figura 5.11: Gráficos de dispersión de la precipitación acumulada mensual de los pronósticos crudos y corregidos con los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.2.1. Sesgo

En la Figura 5.12, los pronósticos crudos presentan un sesgo húmedo en la mayor parte del año, llegando al máximo porcentaje de sesgo en noviembre. El método LS corrige eficientemente el sesgo todos los meses del año, no así el método QM, que presenta sesgo levemente pronunciados en los meses de marzo y abril. De manera similar que con los pronósticos temperatura, el sesgo depende mayormente del mes en estudio que del mes de adelanto, sin embargo, existe mayor variabilidad sesgo entre los meses de adelanto.




Figura 5.12: Sesgo porcentual de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

En la Figura 5.13, se observa en los pronósticos crudo que se acentúa un sesgo húmedo en la zona norte, el cual se prolonga hacia el sur por la zona costera en EFM y por la zona cordillerana en AMJ y JAS. La zona sur presenta un sesgo seco de menor magnitud. El sesgo porcentual máximo en OND es de 585,5 [%] y el mínimo de -54,5 [%] en EFM. Con el método LS el sesgo alcanza valores entre -6,5 [%] en EFM y 5,2 [%] en OND. En el caso del método QM, presenta un sesgo húmedo en la zona norte y alcanza valores entre -5,2 [%] en AMJ y 19,7 [%] en EFM.

Tabla 5.7: Celdas con valores máximos y mínimos de sesgo porcentual trimestral de precipitación.

Método	Máximo Sesgo [%]				Mínimo Sesgo [%]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	570,7	258,5	371,3	585,5	-54,5	-20,4	-35,0	-44,1
LS	3,7	0,2	1,1	5,2	-6,5	-1,3	-2,2	-2,1
QM	19,7	13,4	12,9	14,6	-1,6	-5,2	-1,4	-3,1

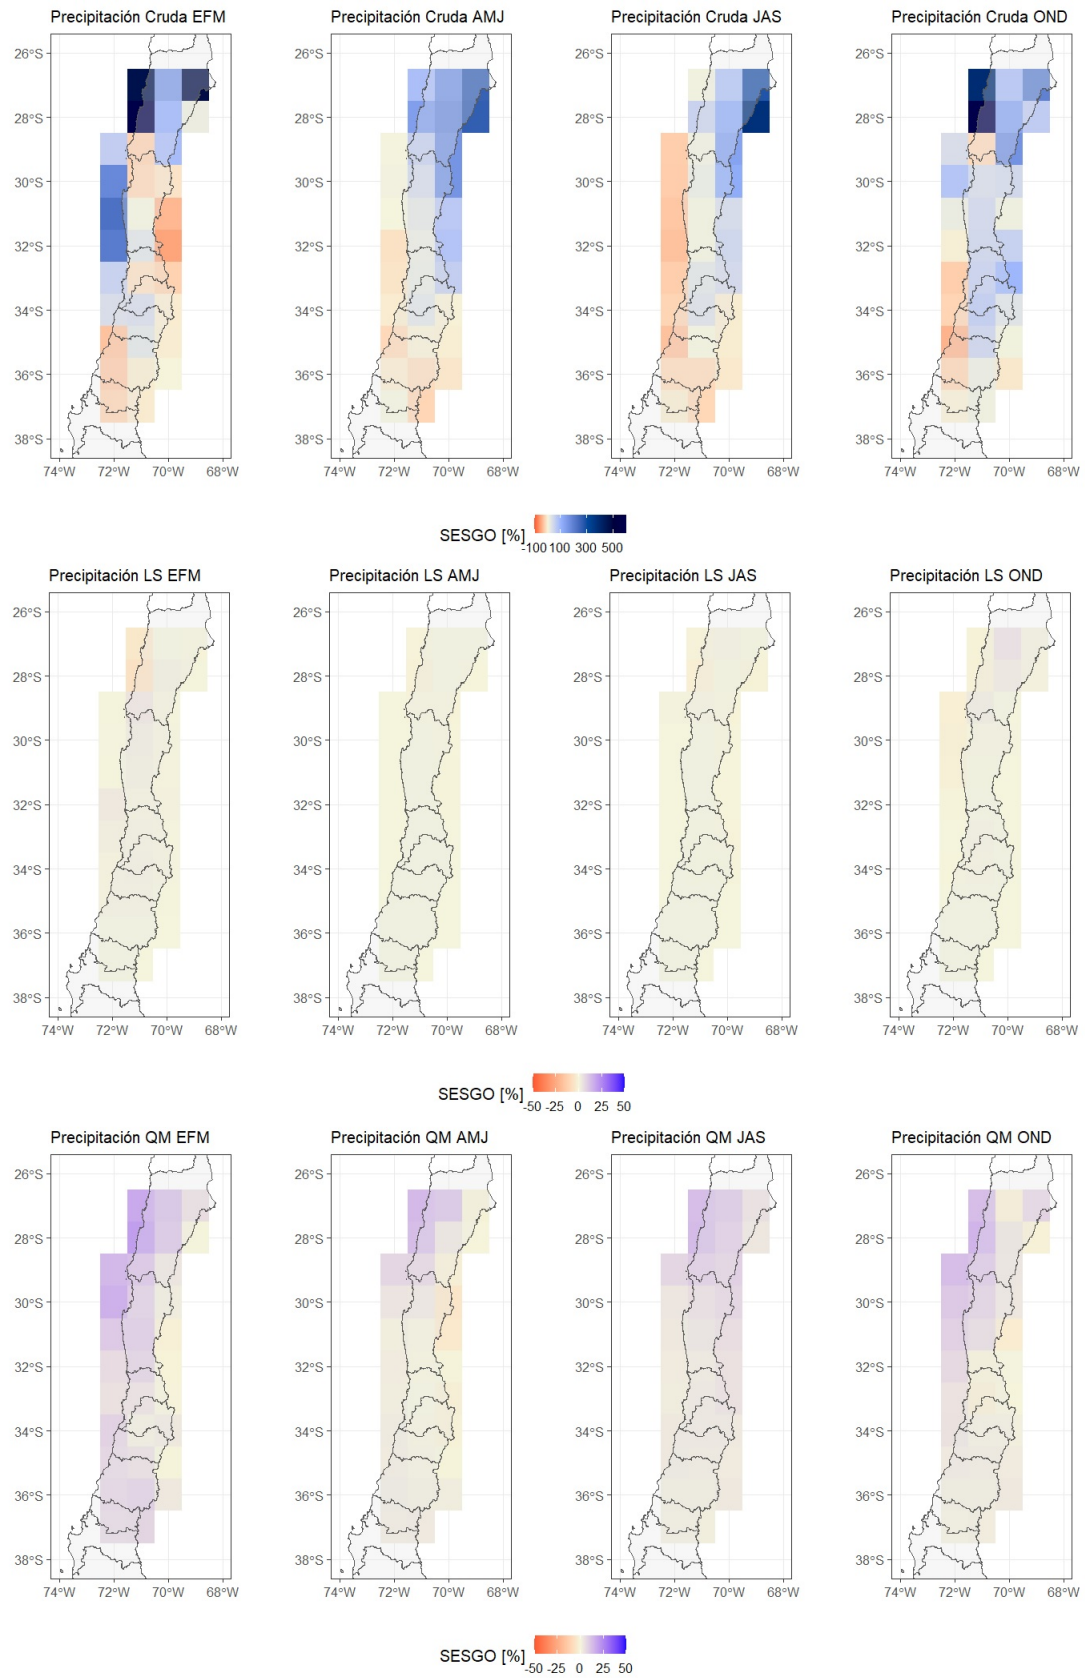


Figura 5.13: Sesgo porcentual de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.2.2. Raíz del Error Cuadrático Medio Normalizado

En la Figura 5.14, los pronósticos crudos presentan el mínimo error los primeros meses de adelanto, exceptuando enero y febrero. Al aplicar los métodos de post-procesamiento, no se observa bajas significativas del error. Por otro lado, se observa mayor variabilidad del error entre meses de adelanto en primavera y depende mayormente del mes en estudio que del mes de adelanto.




Figura 5.14: NRMSE de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

En la Figura 5.15, se observa que el NRMSE de los pronósticos crudos es mayor en la zona norte y disminuye hacia la zona sur. Alcanza su valor máximo (6,96) y mínimo (0,28) en EFM. La corrección de los pronósticos con los métodos LS y QM no mejora significativamente el NRMSE, salvo los valores máximos observados en la zona norte (Tabla 5.8). En el caso de los valores mínimos, no se percibe una baja considerable con los métodos de corrección.

Tabla 5.8: Celdas con valores máximos y mínimos de NRMSE porcentual trimestral de precipitación.

Método	Máximo NRMSE [-]				Mínimo NRMSE [-]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	7,0	2,8	3,9	6,2	0,3	0,3	0,3	0,3
LS	4,9	1,2	0,8	1,8	0,3	0,3	0,3	0,3
QM	3,7	1,1	0,8	1,5	0,2	0,3	0,3	0,3

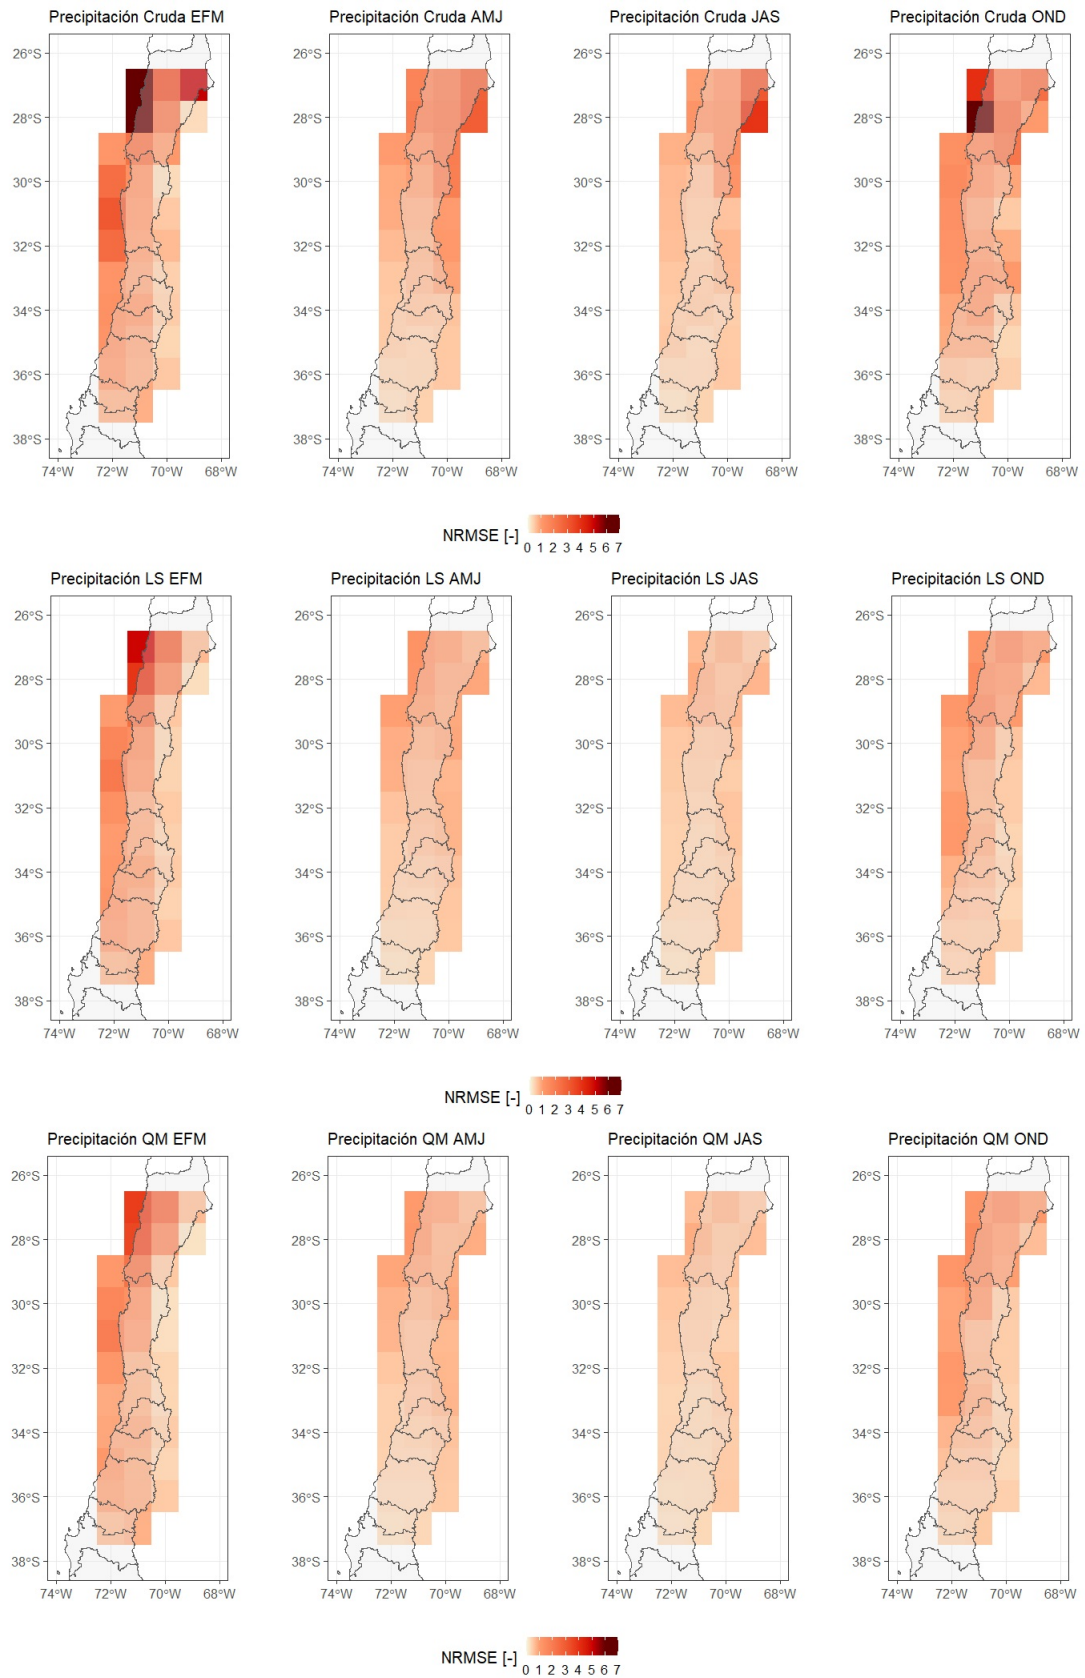


Figura 5.15: NRMSE de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.2.3. Coeficiente de Determinación (R^2)

Se observa la Figura 5.16 que el R^2 de los pronósticos crudos, de manera similar que las métricas anteriores, sigue dependiendo mayormente del mes en estudio que del mes de adelanto. El primer mes de adelanto es el de mejor desempeño, exceptuando los meses de enero y febrero. En el caso de los pronósticos corregidos no se observan mejoras significativas del R^2 , salvo en algunos meses como enero y febrero.




Figura 5.16: R^2 de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

En la Figura 5.17, se observa que la distribución espacial del R^2 de los pronósticos crudos es relativamente homogénea en EFM y AMJ, teniendo gran cantidad de valores nulos. En JAS se obtiene el máximo R^2 , 0,7 (Tabla 5.9), en la zona norte. En el caso de los métodos de corrección no se observa una mejora significativa con respecto a los pronósticos crudos.

Tabla 5.9: Celdas con valores máximos y mínimos de R^2 trimestral de precipitación.

Método	Máximo R^2 [-]				Mínimo R^2 [-]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	0,6	0,2	0,7	0,7	0,0	0,0	0,1	0,0
LS	0,5	0,4	0,7	0,7	0,0	0,0	0,1	0,0
QM	0,6	0,7	0,7	0,7	0,0	0,0	0,2	0,0

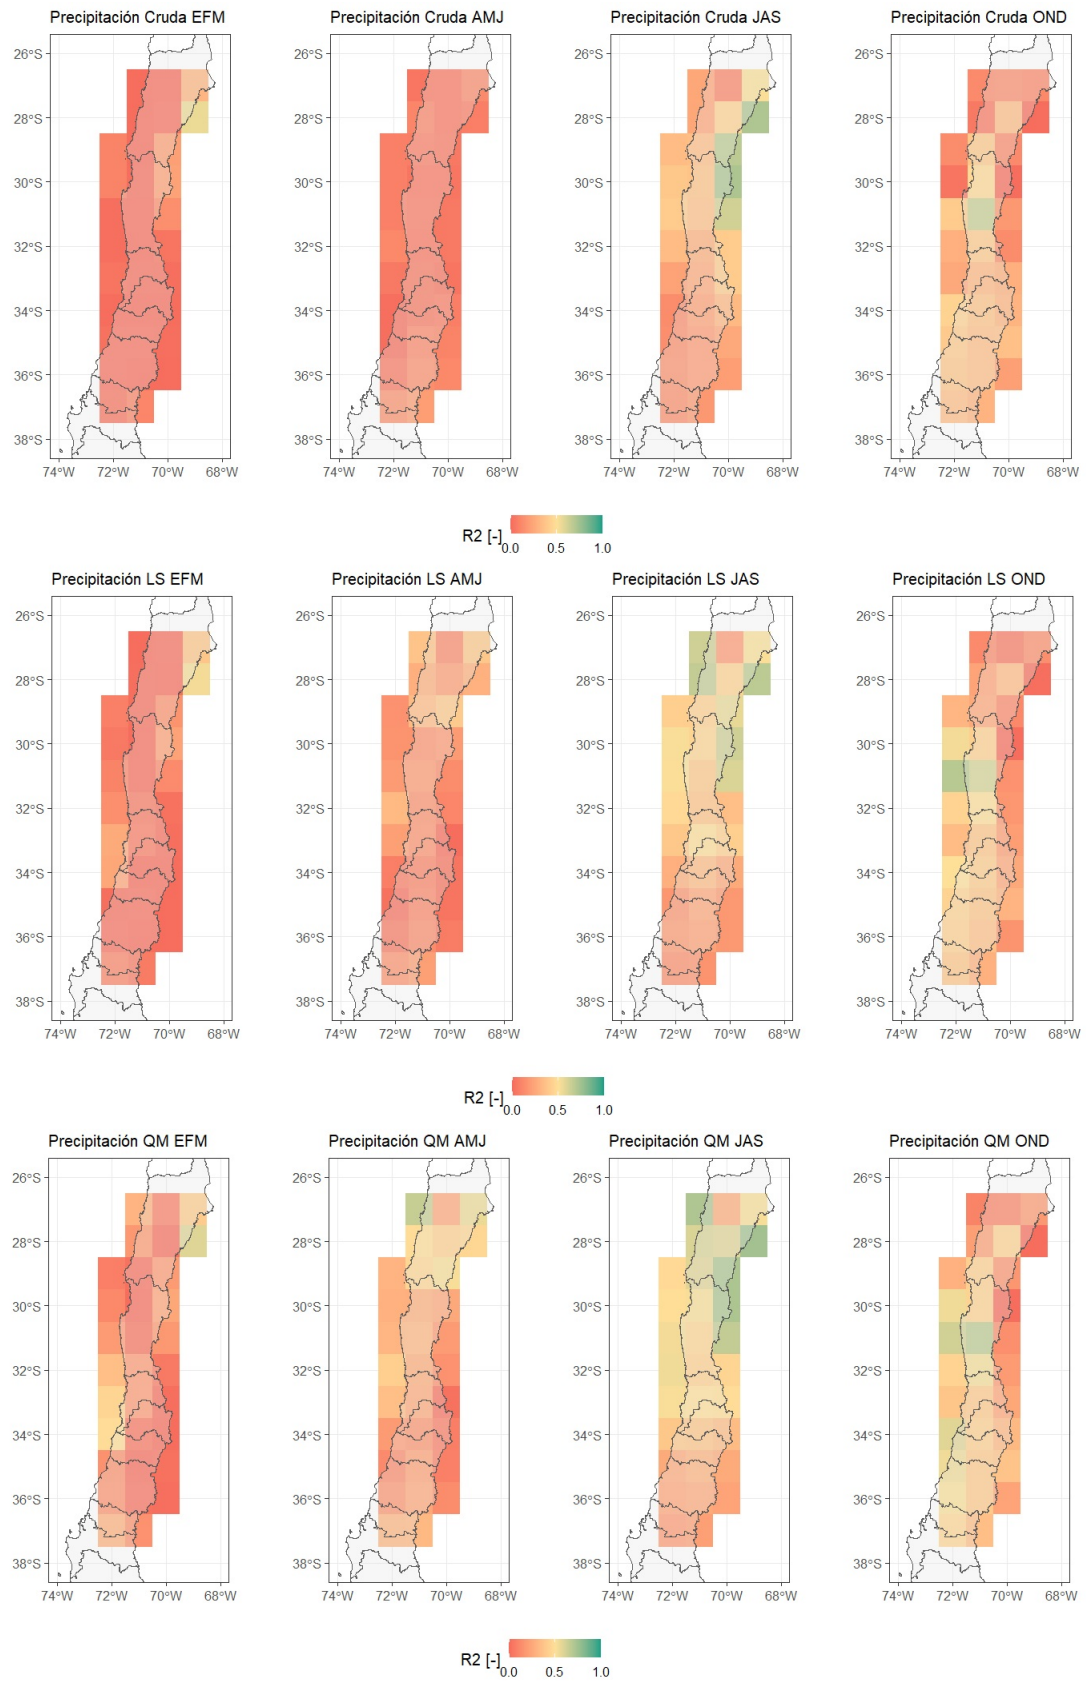


Figura 5.17: R^2 de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

5.2.4. Habilidad de puntuación de probabilidad clasificada continua (CRPSS)

Se observa en la Figura 5.18 que el CRPSS de pronósticos crudos es mayor para el primer mes de adelanto, exceptuando enero febrero y marzo. Además, se obtiene que el CRPSS es positivo para casi todos los meses de adelanto, exceptuando de mayo a septiembre. Cabe destacar que entre los meses enero-abril y octubre-diciembre, el CRPSS es positivo independiente del mes de adelanto (Figura 5.18). Tras el post-procesamiento se obtienen mejoras moderadas, donde destaca el aumento de meses con CRPSS positivo.




Figura 5.18: CRPSS de los pronósticos de precipitación acumulada mensual crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016. El eje x representa el mes en estudio, mientras que los colores representan los meses de adelanto.

Se observa en la Figura 5.9 que el CRPSS para los pronósticos crudos es homogéneo en la zona sur con valores positivos cercanos a 0, mientras que en la zona norte se tienen valores negativos que alcanzan -5,9 en OND (Tabla 5.10). En el caso del método LS se observa que el CRPSS es negativo en la zona cordillerana del trimestre EFM, es prácticamente positivo en toda la zona de estudio del trimestre OND y es levemente mayor en la zona norte que en la zona sur en los trimestres AMJ y JAS. Con el método QM se observa un comportamiento similar, salvo en el trimestre EFM donde el CRPSS negativo abarca menor área. Ambos métodos aumentan de manera si miliar la cantidad de celdas con CRPSS positivo (Tabla 5.11). Prácticamente en la totalidad de la zona de estudio (32 celdas) se tiene un CRPSS positivo luego del post-procesamiento, exceptuando el trimestre EFM (Tabla 5.11). En la Figura 5.20, ambos métodos presentan resultados similares. El CRPSS es mayor en la zona norte, mientras que es levemente negativo en la zona sur, con una gran cantidad de celdas con CRPSS positivo (Tabla 5.12).

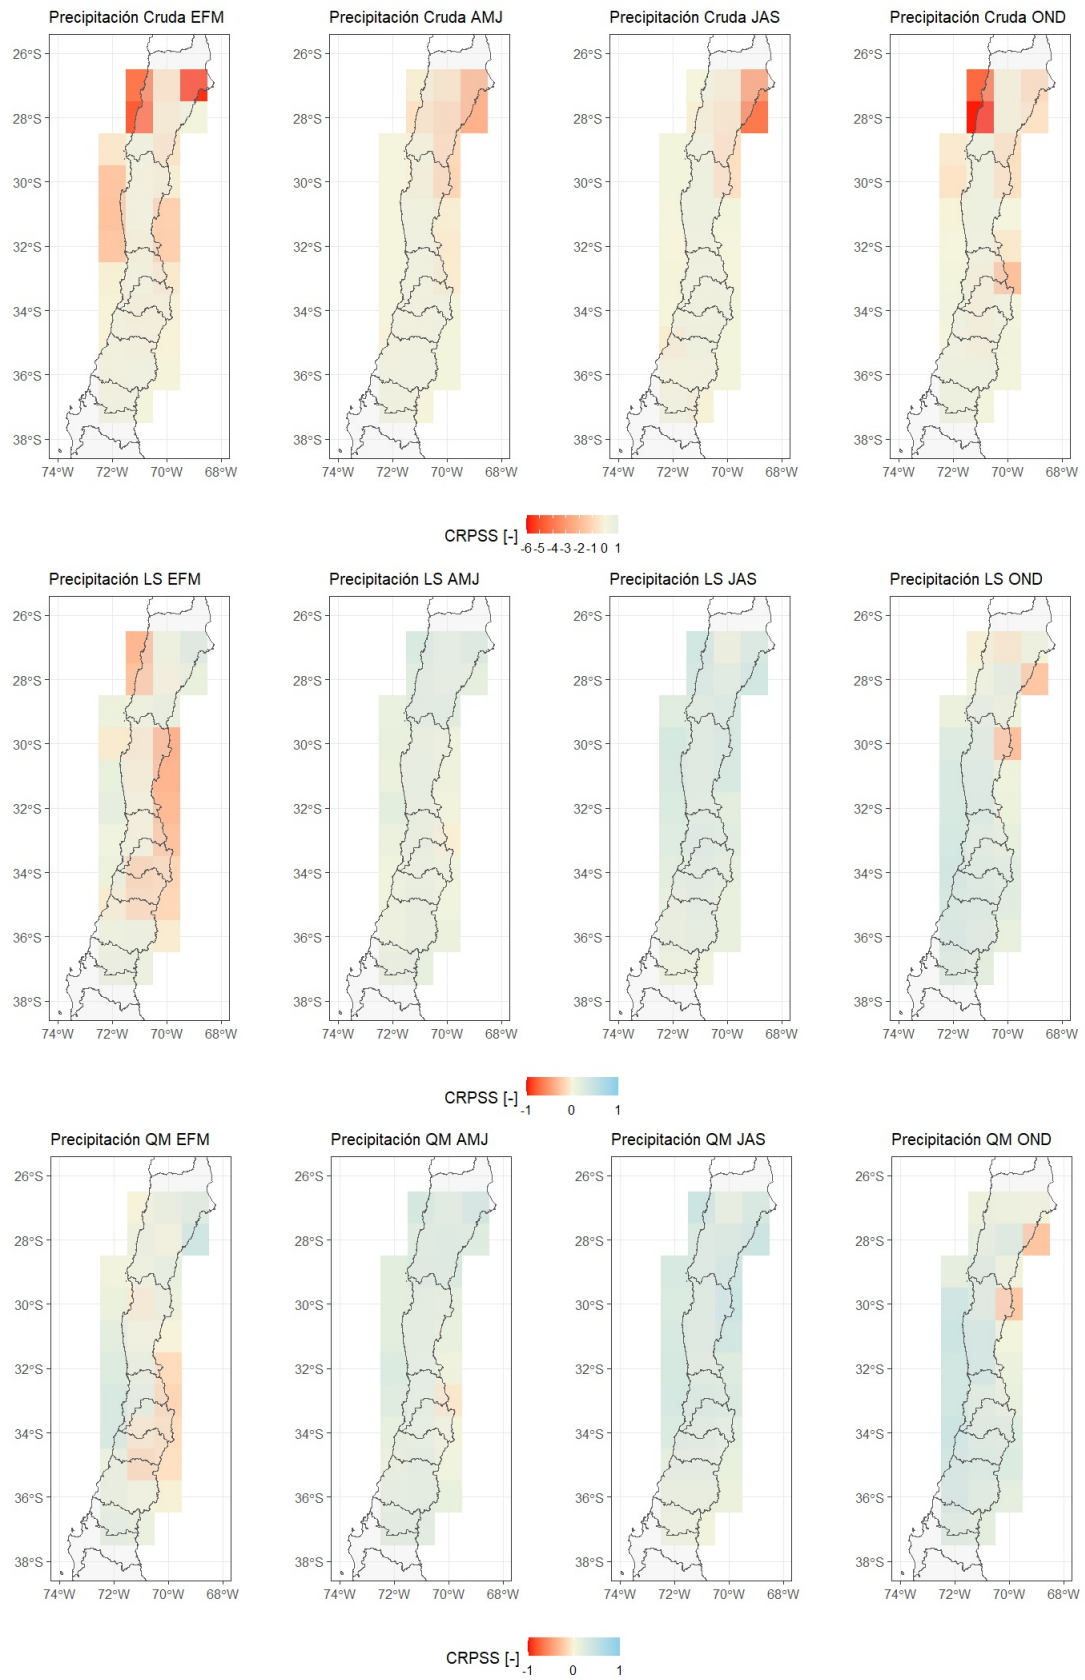


Figura 5.19: CRPS, con la climatología como referencia, de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

Tabla 5.10: Celdas con valores máximos y mínimos de CRPSS trimestral de precipitación, utilizando como referencia la climatología.

Método	Máximo CRPSS [-]				Mínimo CRPSS [-]			
	EFM	AMJ	JAS	OND	EFM	AMJ	JAS	OND
Crudo	0,1	0,1	0,2	0,3	-5,6	-2,2	-4,0	-5,9
LS	0,3	0,3	0,4	0,4	-0,4	0,0	0,0	-0,3
QM	0,4	0,4	0,4	0,4	-0,2	-0,1	0,0	-0,2

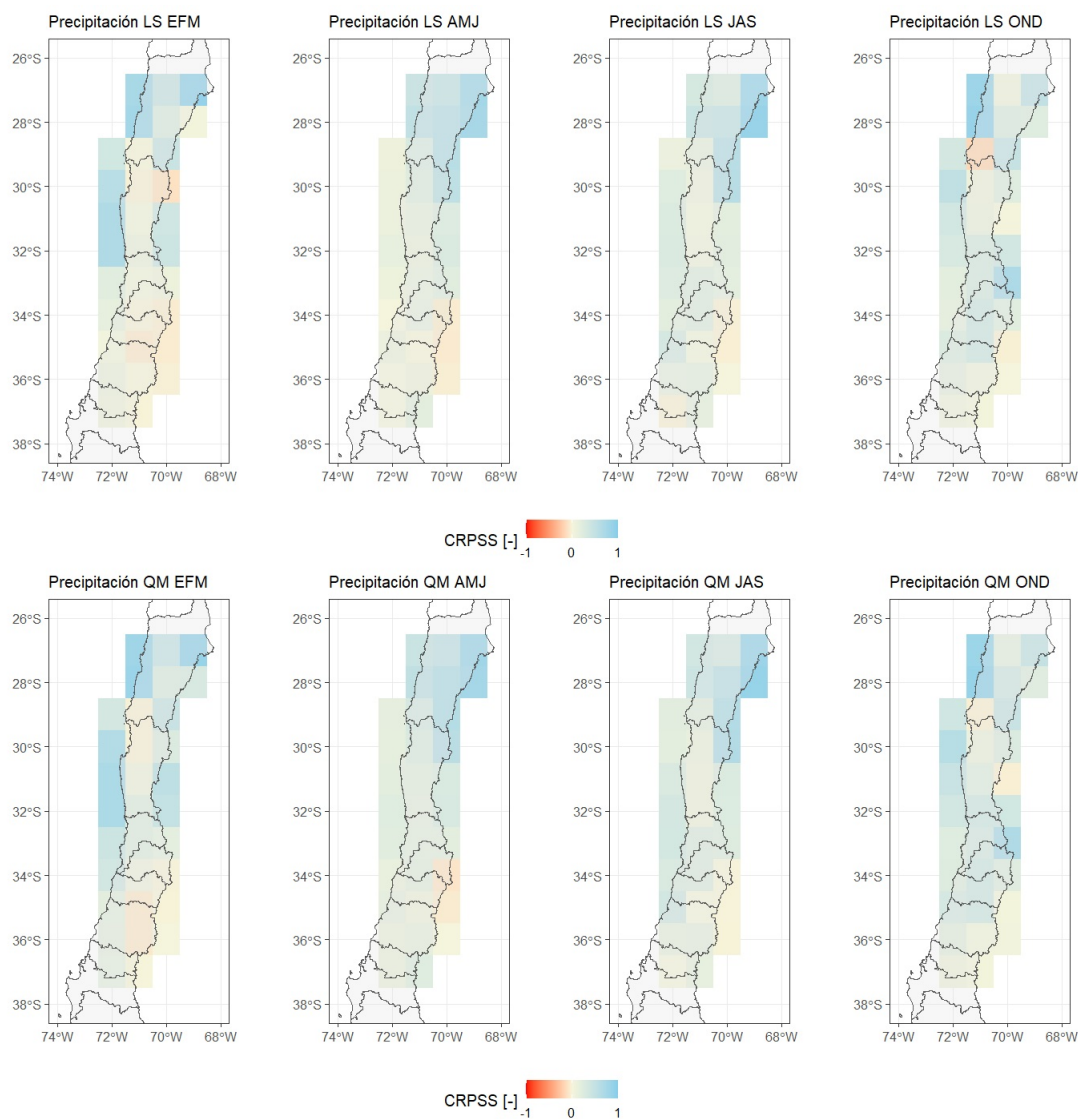


Figura 5.20: CRPSS, con los pronósticos crudos como referencia, de los pronósticos de precipitación acumulada trimestral crudos y corregidos mediante los métodos Mapeo de Cuantiles (QM) y Escalamiento Lineal (LS), para cada celda de la zona de estudio en el periodo 1993-2016.

Tabla 5.11: Número de celdas con CRPSS positivo para los valores trimestrales de precipitación, utilizando como referencia la climatología.

Numero de celdas (CRPSS > 0)				
Método	EFM	AMJ	JAS	OND
Crudo	5	12	16	15
LS	14	31	32	28
QM	21	31	32	30

Tabla 5.12: Número de celdas con CRPSS positivo para los valores trimestrales de precipitación, utilizando como referencia los pronósticos crudos.

Numero de celdas (CRPSS > 0)				
Método	EFM	AMJ	JAS	OND
LS	22	28	29	30
QM	25	29	29	30

Capítulo 6

Discusión

En esta sección, se discuten los resultados obtenidos en términos de los atributos de sesgo, precisión, asociación, habilidad (asociado a la precisión) y coherencia de los pronósticos crudos y corregidos, según tiempo de adelanto, distribución espacial y estaciones del año.

6.1. Temperatura

Al evaluar las métricas tanto de los pronósticos crudos como corregidos los resultados dependen principalmente del mes en estudio, teniendo el tiempo de adelanto menos impacto en las métricas, lo que concuerda con los resultados de Lucatero et al. (2018) en Dinamarca. En el caso de del gráfico de dispersión (Figura 5.1), se observa que el desempeño del sistema SEAS5 es deficiente para pronósticos de temperaturas bajas.

Al considerar toda la zona de estudio, se evidencia que predomina un sesgo frío durante todo el año (Figura 5.2), a diferencia de lo que determinan Lucatero et al. (2018) con el producto SEAS4 en Dinamarca, donde el sesgo es mayoritariamente cálido en los meses de verano. Esto puede deberse a la topografía de la zona de estudio, que se caracteriza por ser de baja altitud. En la Figura 5.3, se muestra que el sesgo frío es provocado principalmente por la cordillera y mayormente en periodos fríos, lo cual se puede deber a que los GCMs no son suficientes para modelar procesos a escala local. Tras aplicar los métodos de post-procesamiento, ambos métodos reducen el sesgo efectivamente para cada mes de inicialización y mes de adelanto (Figura 5.2), al igual que en Lucatero et al. (2018). Esto también se observa espacialmente para cada estación del año (Figura 5.3).

En términos de precisión, se puede observar nuevamente que el desempeño del pronóstico crudo es deficiente en la zona cordillerana y los meses fríos (Figura 5.5). Por otro lado, el pronóstico tiende a ser más preciso para el primer mes de adelanto durante todo el año (Figura 5.4). El RMSE de los pronósticos corregidos se acerca más al valor óptimo utilizando ambos métodos (Figura 5.4), siendo el primer mes de adelanto el de menor error para todos los meses de inicialización, exceptuando julio. En la Tabla 5.2, se puede observar que el método QM tiene menor error que el método LS, llegando a valores más bajos de RMSE.

Respecto al atributo de asociación, existe mayor correlación de los datos al considerar todas las celdas de la zona de estudio (Figura 5.6), donde la correlación es cercana a 1 durante todo el año, que al considerar cada celda por separado (Figura 5.7), donde llega a ser 0 en algunos trimestres. Esto puede ser debido a la inclusión de mayor cantidad de pares pronóstico-observación, como se observa las figuras del Anexo A, donde existe mayor correlación al considerar más cantidad de datos. se observa que no hay una mejora significativa para ningún mes ni trimestre en estudio.

En términos de habilidad, al igual que con la precisión, es menos "hábil" que la climatología en la zona cordillerana en periodos fríos (Figura 5.9). Además, el CRPSS promedio en la zona de estudio es negativo durante todo el año (Figura 5.8), lo que significa que el modelo de pronósticos SEAS5 es menos preciso que la climatología, es decir, no garantiza coherencia. Esto difiere de lo encontrado por Lucatero et al. (2018) en Dinamarca, donde el CRPSS promedio para toda la zona de estudio es positivo para todas las inicializaciones de pronóstico con 1 mes de adelanto, exceptuando abril y mayo. Esto puede atribuir a la diferencia en la topografía de las zonas de estudio, donde la altura máxima de Dinamarca no supera los 171 [m.s.n.m.]. La habilidad de los pronósticos, considerando la climatología, mejora con ambos métodos LS y QM. Se puede observar que para todos los meses con un mes de adelanto, al menos, el CRPSS garantiza coherencia (CRPSS positivo), exceptuando julio (Figura 5.8). A pesar de que en algunos sectores de la zona de estudio el CRPSS se mantiene negativo después de aplicar ambos métodos (Figura 5.9), el número de celdas con CRPSS positivo aumenta considerablemente (Tabla 5.5), en especial con el método LS. De igual manera ocurre en Lucatero et al. (2018), donde aumenta una gran porción de celdas positivas en Dinamarca para el primer mes de adelanto al aplicar los métodos de corrección. Por otro lado, se observa en las Tablas 5.6 prácticamente todas las celdas tienen un CRPSS positivo, lo que significa que ambos métodos mejoran la precisión de los pronósticos crudos.

6.2. Precipitación

Al igual que en el caso de la temperatura, las métricas de evaluación de los pronósticos dependen predominantemente del mes que se evalúa, y en mucha menor medida del tiempo de adelanto, lo cual concuerda con Lucatero et al. (2018) y Crochemore et al. (2016). En el caso de del gráfico de dispersión (Figura 5.11), se observa que al producto tiene bajo desempeño pronosticando altas precipitaciones. Además, se observa una alta densidad de puntos para bajas precipitaciones (Figura 6.1), lo que se puede deber al *efecto llovizna* (Wetterhall et al., 2015). Tras el post-procesamiento, en el gráfico de dispersión (Figura 5.11) se observa que, a pesar de aumentar la dispersión a precipitaciones altas, ambos métodos tienden a mejorar el error moderadamente los meses de altas lluvias acercándolos levemente a las observaciones.




Figura 6.1: Mapa de dispersión del pronóstico de precipitación junto con un histograma de frecuencia.

Se observa en la Figura 5.12 un sesgo mayoritariamente húmedo, especialmente marcado en los meses de octubre y noviembre. En cuanto al sesgo en la zona de estudio, en la Figura 5.13 se observa que en la zona norte predomina un sesgo húmedo, el cual se puede explicar debido al *efecto llovizna*, ya que esta zona se caracteriza por bajas precipitaciones. Ambos métodos son efectivos en la reducción de sesgo para todos los meses de inicialización y mes de adelanto (Figura 5.12), al igual que en Crochemore et al. (2016), Lucatero et al. (2018) y Zhao et al. (2017). En el caso del método QM, aún se mantiene un sesgo húmedo moderado en la zona norte en todas las estaciones del año (Figura 5.13), lo que se puede explicar debido a las bajas o casi nulas precipitaciones en la zona.

En términos de precisión, se puede observar que el NRMSE es bajo en durante todo el año, alcanzando el máximo error en los meses cálidos (Figura 5.14), los cuales se caracterizan por escasas precipitaciones. Esto se reafirma en la Figura 5.15, donde el desempeño de los pronósticos es bajo en periodos cálidos y zonas de mayor sequía. En la Figura 5.14, no se aprecia alguna mejora significativa en la precisión del pronóstico. En la Figura 5.15, se observa que la mayor reducción de NRMSE ocurre en JAS y OND, trimestres con mayor R^2 . (Figura 5.17). Zhao et al. (2017) plantean que el método QM es más efectivo cuando existe alta correlación entre los datos, es decir, mayor R^2 .

En el caso del atributo de asociación, nuevamente existe mayor correlación entre los datos al considerar todas las celdas de la zona de estudio (Figura 5.6) que analizando cada celda por separado (Figura 5.7), donde alcanza el 0 en algunos trimestres. Al igual que en el caso de la temperatura, esto puede ser debido a la inclusión de mayor cantidad de pares pronóstico-observación, como se observa las figuras del Anexo B, donde existe mayor correlación al considerar más cantidad de datos. No se observan mejoras significativas al aplicar los métodos de post-procesamiento.

Con respecto a la habilidad, se tiene una gran porción de meses con CRPSS positivo, lo que implica que el sistema de pronósticos es más hábil que la climatología (Figura 5.18). En la Figura 5.19, se muestra la baja habilidad del pronóstico en la zona norte y primavera-verano, zona mayormente árida y periodo de temperaturas altas. Sin embargo, alrededor de la mitad de las celdas llegan a valores de CRPSS mayores a cero (Tabla 5.11)). Ambos métodos de post-procesamiento mejoran el CRPSS, al menos para el primer mes de adelanto, obteniendo valores positivos para todos los meses (Figura 5.18). En Lucatero et al. (2018) se obtienen resultados parecidos; sin embargo, en la corrección de sesgo llevada a cabo en este estudio, se obtienen varios meses de adelanto con CRPSS positivos. En el caso del LS, en la Figura ??, se obtiene la mayoría de celdas con CRPSS positivo, exceptuando en EFM (14 celdas, Tabla 5.12). En Wang et al. (2019) se obtienen resultados parecidos al aplicar el método LS para los pronósticos SEAS5 en Australia, a pesar de la diferencia de la topografía entre las zonas de estudio, donde el territorio australiano no supera los 2200 [m.s.n.m.]. Con respecto al método QM, en Zhao et al. (2017) en Australia, se obtienen varias celdas negativas durante el año utilizando el producto de pronósticos de POAMA. Finalmente, se obtiene una cantidad de celdas importantes (>68 %) con CRPSS positivo cuando se utiliza como referencia los pronósticos crudos, lo que implica una significativa mejora de los pronósticos mediante los métodos de post-procesamiento. La dificultad de pronosticar la precipitación radica su fenomenología, ya que es un proceso intermitente y responde frente a procesos caóticos.

6.3. Post-procesamiento

En este estudio se emplean dos métodos de corrección de sesgo comúnmente utilizados en el post-procesamiento de pronósticos (Corchemore et al., 2016; Lucatero et al., 2018; Zhao et al., 2017; Wang et al., 2019; Trambauer et al., 2014; Watterhall et al., 2014; Switanek et al. (2017); Teutschbein y Seibert., 2012). Sin embargo, existen otros métodos que han tenido buenos resultados. Zhao et al., 2017 aplica el método de Probabilidad Conjunta Bayesiana (BJP) y obtienen mejor desempeño que QM, donde no solo corrigen el sesgo del pronóstico si no que también mejoran la confianza y la coherencia. Por otro lado, el método QM no considera el cambio climático al asumir un comportamiento estacionario de las variables y Switanek et al. (2017) exponen que se debe considerar el cambio climático en la corrección de sesgo. En esta línea, proponen un método llamado Mapeo de Cuantiles Delta (QDM), el cual considera la no estacionariedad del clima al considerar eventos futuros en los factores de corrección. Respecto al método LS, Teutschbein y Seibert. (2012) se comparan su desempeño con varios métodos de corrección en Suecia, siendo el tercero de mejor desempeño detrás de los métodos Mapeo de Distribución (DM) y Escalamiento de Varianza (VS), en el caso de la temperatura, y cuarto detrás de los métodos Mapeo de Distribución (DM), Fuerza de Transmisión (PT) y Escalamiento de Intensidad Local (LOCI) en el caso de la precipitación.

Capítulo 7

Conclusiones

A partir de la evaluación de los pronósticos meteorológicos crudos y corregidos mediante los métodos QM y LS, se puede concluir que:

1. El desempeño de los pronósticos crudos de precipitación y temperatura en base a las tres métricas utilizadas depende principalmente del mes en que se está evaluando, no así de con cuanto tiempo se ha emitido dicho pronóstico.
2. Los pronósticos crudos presentan peor rendimiento en las celdas que se encuentran en la cordillera.
3. En cuanto a la coherencia de los pronósticos crudos, es decir, la posible ganancia de usar los pronósticos en vez de la climatología; el producto de temperatura no garantiza coherencia, a diferencia del producto de precipitación que al menos para un mes de adelanto de, si lo garantiza.
4. Tras el post-procesamiento mediante los métodos QM y LS, el sesgo se reduce casi a cero para ambas variables y ambos métodos, para los distintos meses y tiempos de adelanto. El RMSE y CRPSS presentan una mejora considerable en el caso de la temperatura, lo que no se observa en la corrección de precipitación.
5. En términos de precisión, ambos métodos de post-proceso mejoran la calidad de los pronósticos de temperatura, no así en el caso del producto de precipitación.
6. En cuanto a la coherencia de los pronósticos corregidos, es decir, la posible ganancia de usar los pronósticos en vez de la climatología; tanto el producto de temperatura (moderadamente) como el de precipitación garantizan coherencia en su primer mes de adelanto.
7. Los métodos de post-procesamiento no presentan grandes diferencias para las distintas métricas. Sin embargo, el costo computacional del método QM es muy superior al del LS, por lo que con los resultados obtenidos no se justifica utilizar el método de Mapeo de Cuantiles.

Finalmente, los resultados de este estudio reflejan el potencial que tienen los pronósticos climáticos en la mejora de la gestión hídrica en Chile. Si bien, los métodos de post-procesamiento utilizados no fueron efectivos al corregir el producto de precipitación, se obtuvieron resultados favorables en el post-procesamiento del producto de temperatura. En esta línea, queda propuesto aplicar otras técnicas de post-procesamiento que corrijan de manera efectiva o de mejor manera el producto de precipitación, además de evaluar diversos productos de pronósticos con el fin de ampliar el conocimiento sobre la gestión hídrica en el territorio nacional.

Capítulo 8

Bibliografía

Baker, S. A., Wood, A. W., Rajagopalan, B. (2019). Developing subseasonal to seasonal climate forecast products for hydrology and water management. *JAWRA Journal of the American Water Resources Association*, 55(4), 1024-1037.

Boisier, J. P., Alvarez-Garretón, C., Cepeda, J., Osses, A., Vásquez, N., Rondanelli, R. (2018, April). CR2MET: A high-resolution precipitation and temperature dataset for hydroclimatic research in Chile. In *EGU General Assembly Conference Abstracts* (p. 19739).

Bradley, A. A., Demargne, J., Franz, K. J. (2019). Attributes of forecast quality. In *Handbook of Hydrometeorological Ensemble Forecasting* (pp. 849-892). Springer, Berlin, Heidelberg.

Brier, G. W. (1950). Verification of forecasts expressed in terms of probability. *Monthly weather review*, 78(1), 1-3.

Crochemore, L., Ramos, M. H., Pappenberger, F. (2016). Bias correcting precipitation forecasts to improve the skill of seasonal streamflow forecasts. *Hydrology and Earth System Sciences*, 20(9), 3601-3618.

Falvey, M., Garreaud, R. D. (2009). Regional cooling in a warming world: Recent temperature trends in the southeast Pacific and along the west coast of subtropical South America (1979–2006). *Journal of Geophysical Research: Atmospheres*, 114(D4).

Garreaud, R. D., Boisier, J. P., Rondanelli, R., Montecinos, A., Sepúlveda, H. H., Veloso-Aguila, D. (2020). The central Chile mega drought (2010–2018): a climate dynamics perspective. *International Journal of Climatology*, 40(1), 421-439.

Gneiting, T., Balabdaoui, F., Raftery, A. E. (2007). Probabilistic forecasts, calibration and sharpness. *Journal of the Royal Statistical Society, Series B: Statistical Methodology*, 69(2), 243–268.

Hersbach, H. (2000). Decomposition of the continuous ranked probability score for ensemble prediction systems. *Weather and Forecasting*, 15(5), 559-570.

Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., ... Thépaut, J. N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730), 1999-2049.

Horgue, P., Guibert, R., Gross, H., Creux, P., Debenest, G. (2015). Efficiency of a two-step upscaling method for permeability evaluation at Darcy and pore scales. *Computational Geosciences*, 19(6), 1159-1169.

Huang, Z., Zhao, T. (2022). Predictive performance of ensemble hydroclimatic forecasts: Verification metrics, diagnostic plots and forecast attributes. *Wiley Interdisciplinary Reviews: Water*, 9(2), e1580.

IPCC (2021). Summary for Policymakers. In: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press. In Press.

Johnson, S. J., Stockdale, T. N., Ferranti, L., Balmaseda, M. A., Molteni, F., Magnusson, L., ... Monge-Sanz, B. M. (2019). SEAS5: the new ECMWF seasonal forecast system. *Geoscientific Model Development*, 12(3), 1087-1117.

Lucatero, D., Madsen, H., Refsgaard, J. C., Kidmose, J., Jensen, K. H. (2018a). On the skill of raw and post-processed ensemble seasonal meteorological forecasts in Denmark. *Hydrology and Earth System Sciences*, 22(12), 6591-6609.

Madadgar, S., Moradkhani, H., Garen, D. (2014). Towards improved post-processing of hydrologic forecast ensembles. *Hydrological Processes*, 28(1), 104-122.

Marshall, A. G., Hudson, D., Wheeler, M. C., Alves, O., Hendon, H. H., Pook, M. J., Risbey, J. S. (2014). Intra-seasonal drivers of extreme heat over Australia in observations and POAMA-2. *Climate dynamics*, 43(7), 1915-1937.

Mason, S. J., Graham, N. E. (2002). Areas beneath the relative operating characteristics (ROC) and relative operating levels (ROL) curves: Statistical significance and interpretation. *Quarterly Journal of the Royal Meteorological Society: A journal of the atmospheric sciences, applied meteorology and physical oceanography*, 128(584), 2145-2166.

Mendoza, P. A., Rajagopalan, B., Clark, M. P., Cortés, G., McPhee, J. (2014). A robust multimodel framework for ensemble seasonal hydroclimatic forecasts. *Water Resources Research*, 50(7), 6030-6052.

Molteni, F., Stockdale, T., Balmaseda, M., Balsamo, G., Buizza, R., Ferranti, L., ... Vitart, F. (2011). The new ECMWF seasonal forecast system (System 4) (Vol. 49). Reading: European Centre for medium-range weather forecasts.

- Murphy, A. H. (1993). What is a good forecast? An essay on the nature of goodness in weather forecasting. *Weather and forecasting*, 8(2), 281-293.
- Pappenberger, F., Ramos, M. H., Cloke, H. L., Wetterhall, F., Alfieri, L., Bogner, K., Mueller, A., Salamon, P. (2015). How do I know if my forecasts are better? Using benchmarks in hydrological ensemble prediction. *Journal of Hydrology*, 522, 697–713.
- Pechlivanidis, I. G., Crochemore, L., Rosberg, J., Bosshard, T. (2020). What are the key drivers controlling the quality of seasonal streamflow forecasts?. *Water Resources Research*, 56(6), e2019WR026987.
- Peng, Z., Wang, Q. J., Bennett, J. C., Schepen, A., Pappenberger, F., Pokhrel, P., Wang, Z. (2014). Statistical calibration and bridging of ECMWF System4 outputs for forecasting seasonal precipitation over China. *Journal of Geophysical Research: Atmospheres*, 119(12), 7116-7135.
- Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., ... Becker, E. (2014). The NCEP climate forecast system version 2. *Journal of climate*, 27(6), 2185-2208.
- Switanek, M. B., Troch, P. A., Castro, C. L., Leuprecht, A., Chang, H. I., Mukherjee, R., Demaria, E. (2017). Scaled distribution mapping: a bias correction method that preserves raw climate model projected changes. *Hydrology and Earth System Sciences*, 21(6), 2649-2666.
- Teutschbein, C., Seibert, J. (2012). Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of hydrology*, 456, 12-29.
- Trambauer, P., Werner, M., Winsemius, H. C., Maskey, S., Dutra, E., Uhlenbrook, S. (2015). Hydrological drought forecasting and skill assessment for the Limpopo River basin, southern Africa. *Hydrology and Earth System Sciences*, 19(4), 1695-1711.
- Vargas, X., McPhee, J., Vicuña, S., Meza, F., Daniele, L., Rondanelli, R., Lagos, M. (2017, October). Actualización balance hídrico en Chile. Metodología y desafíos en modelación. In *Proceedings of the XXIII Congreso SOCHID*, Valparaíso, Chile (pp. 18-20).
- Wang, Q. J., Shao, Y., Song, Y., Schepen, A., Robertson, D. E., Ryu, D., Pappenberger, F. (2019). An evaluation of ECMWF SEAS5 seasonal climate forecasts for Australia using a new forecast calibration algorithm. *Environmental Modelling Software*, 122, 104550.
- Weisheimer, A., Palmer, T. N. (2014). On the reliability of seasonal climate forecasts. *Journal of the Royal Society Interface*, 11(96), 20131162.

Wetterhall, F., Winsemius, H. C., Dutra, E., Werner, M., Pappenberger, E. (2015). Seasonal predictions of agro-meteorological drought indicators for the Limpopo basin. *Hydrology and Earth System Sciences*, 19(6), 2577-2586.

Zhao, T., Bennett, J. C., Wang, Q. J., Schepen, A., Wood, A. W., Robertson, D. E., Ramos, M. H. (2017). How suitable is quantile mapping for postprocessing GCM precipitation forecasts?. *Journal of Climate*, 30(9), 3185-3196.

ANEXOS

Anexo A

Dispersión de datos de Temperatura

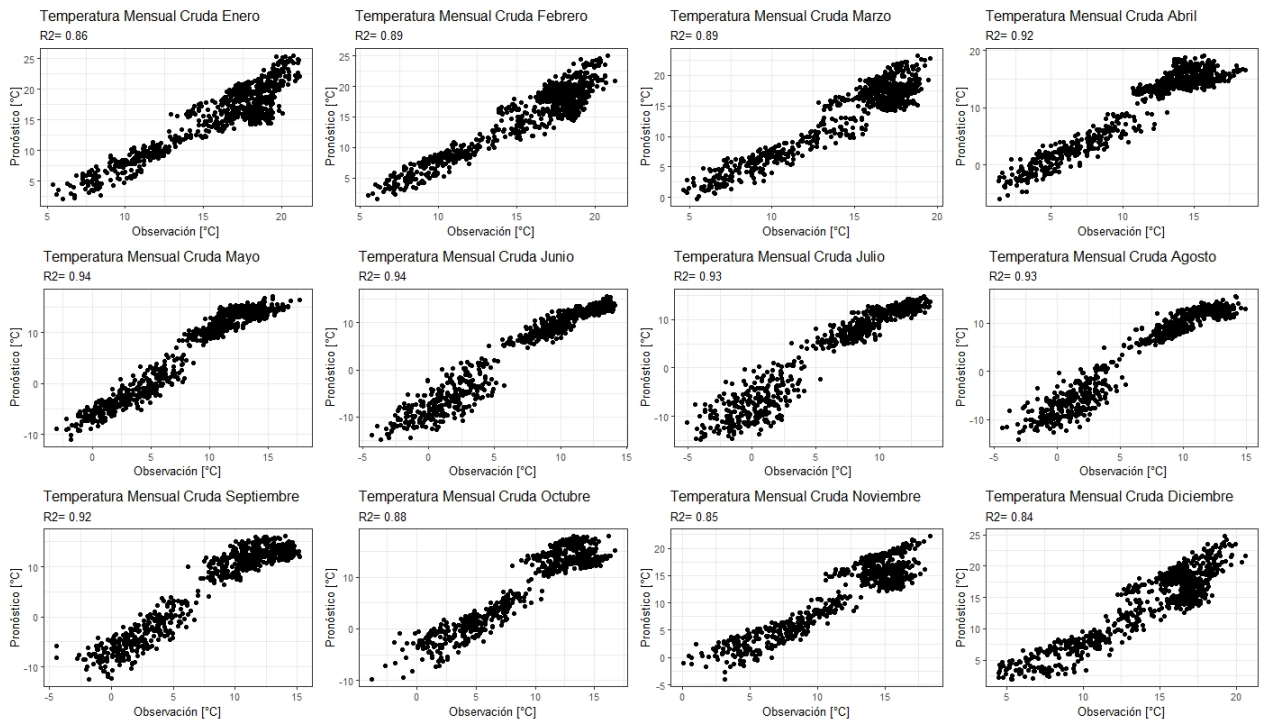


Figura A.1: Gráficos de dispersión de los pronósticos mensuales de temperatura de todas las celdas en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjunto de los pronósticos del primer mes de adelante.

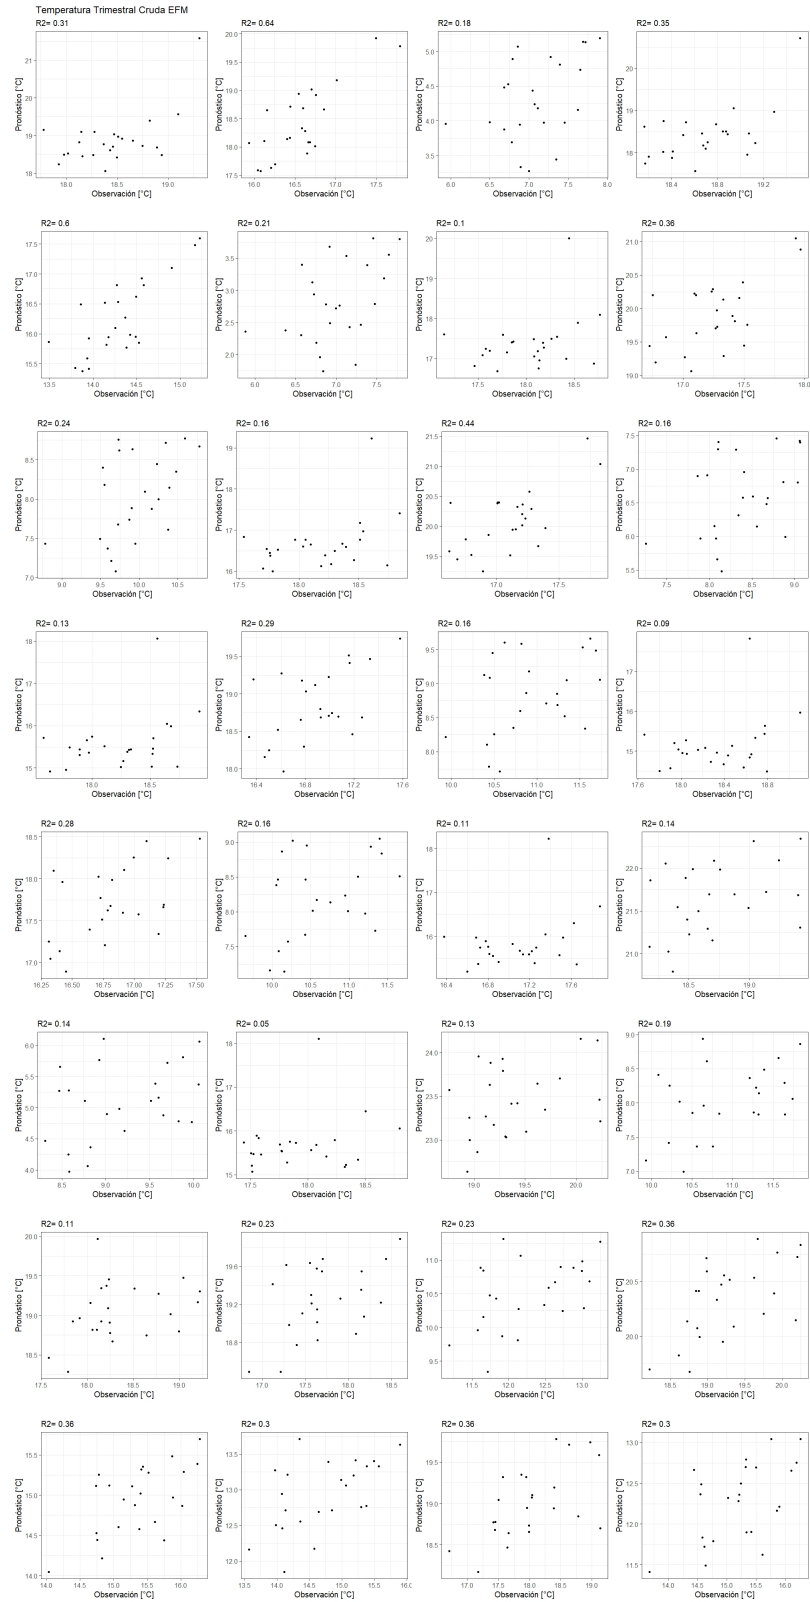


Figura A.2: Gráficos de dispersión del pronóstico crudo de temperatura del trimestre EFM, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos

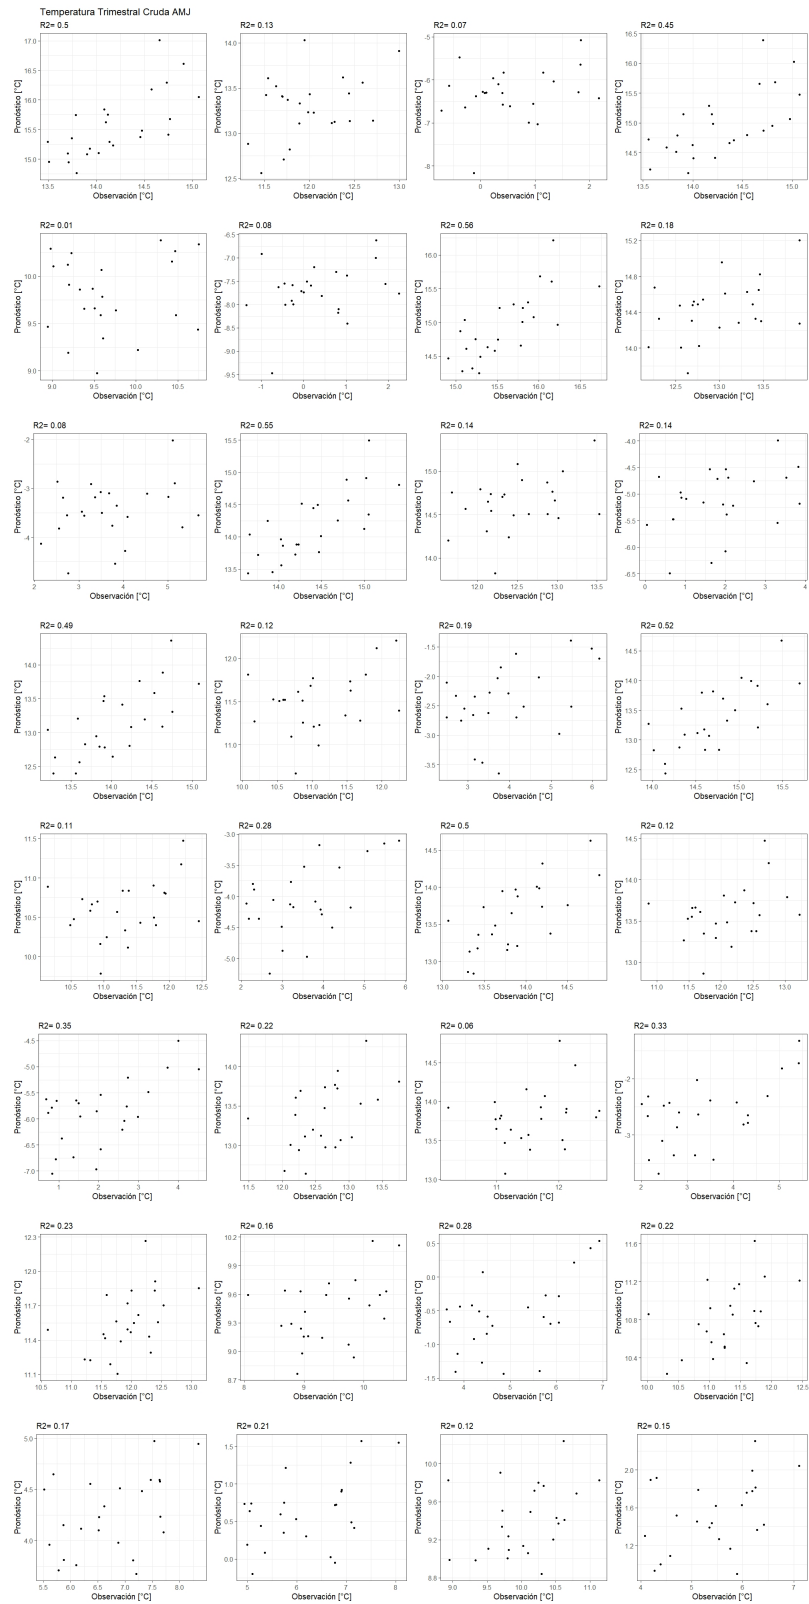


Figura A.3: Gráficos de dispersión del pronóstico crudo de temperatura del trimestre AMJ, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.

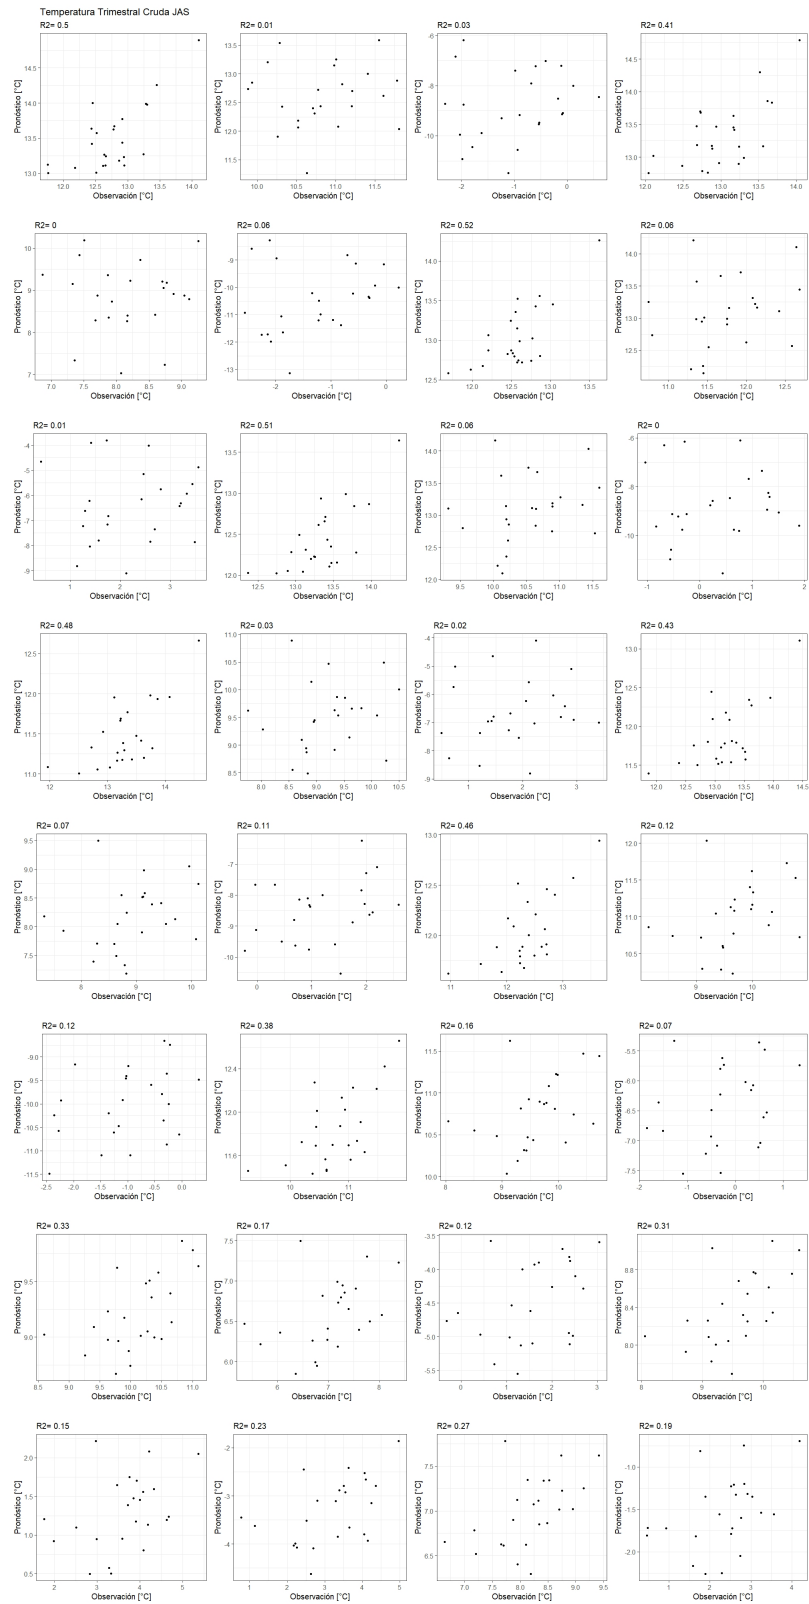


Figura A.4: Gráficos de dispersión del pronóstico crudo de temperatura del trimestre JAS, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.

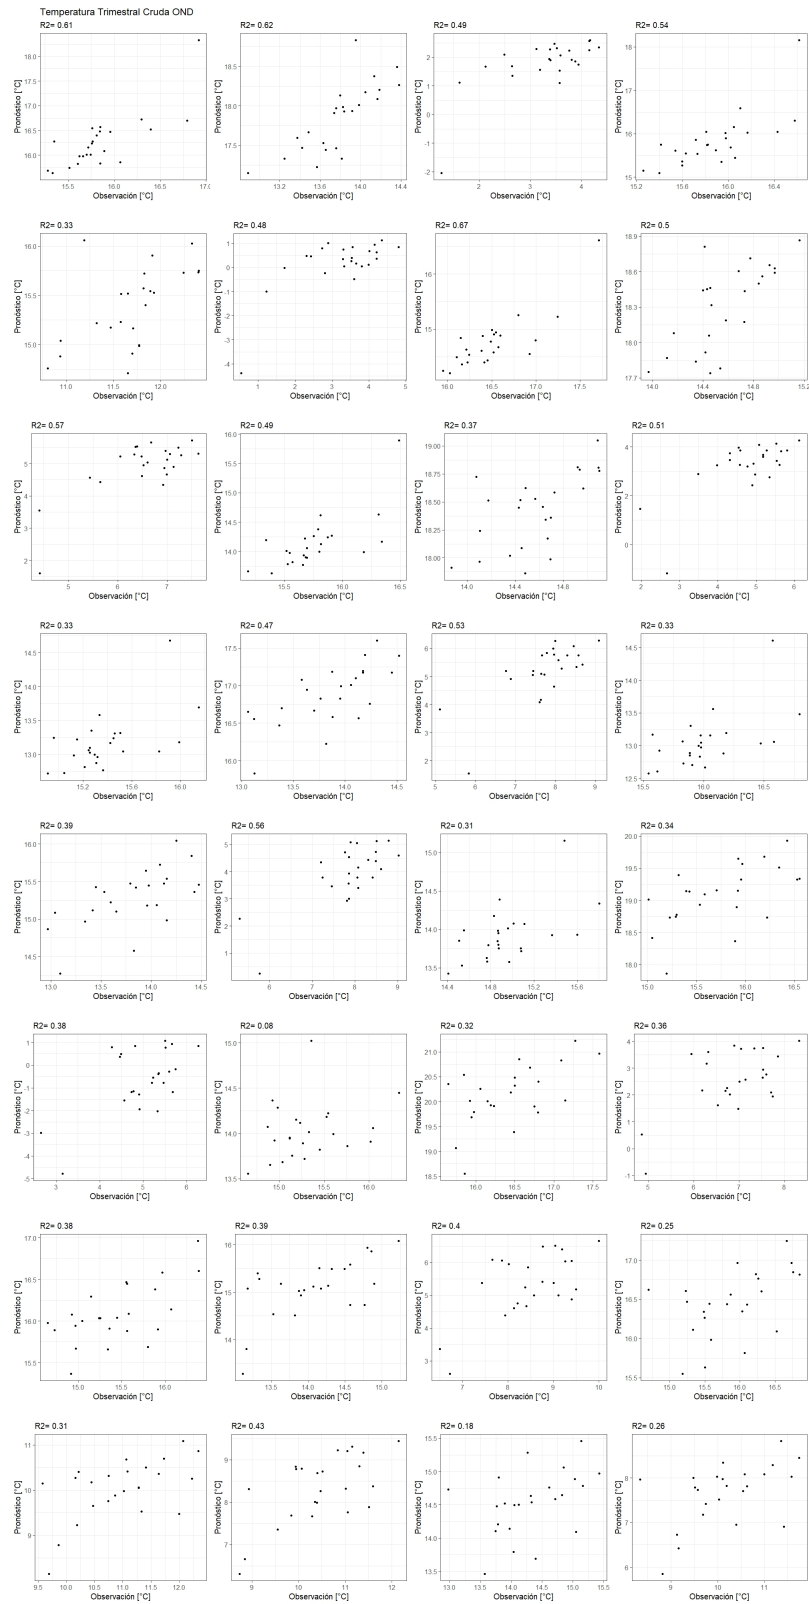


Figura A.5: Gráficos de dispersión del pronóstico crudo de temperatura del trimestre OND, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.

Anexo B

Dispersión de datos de Precipitación

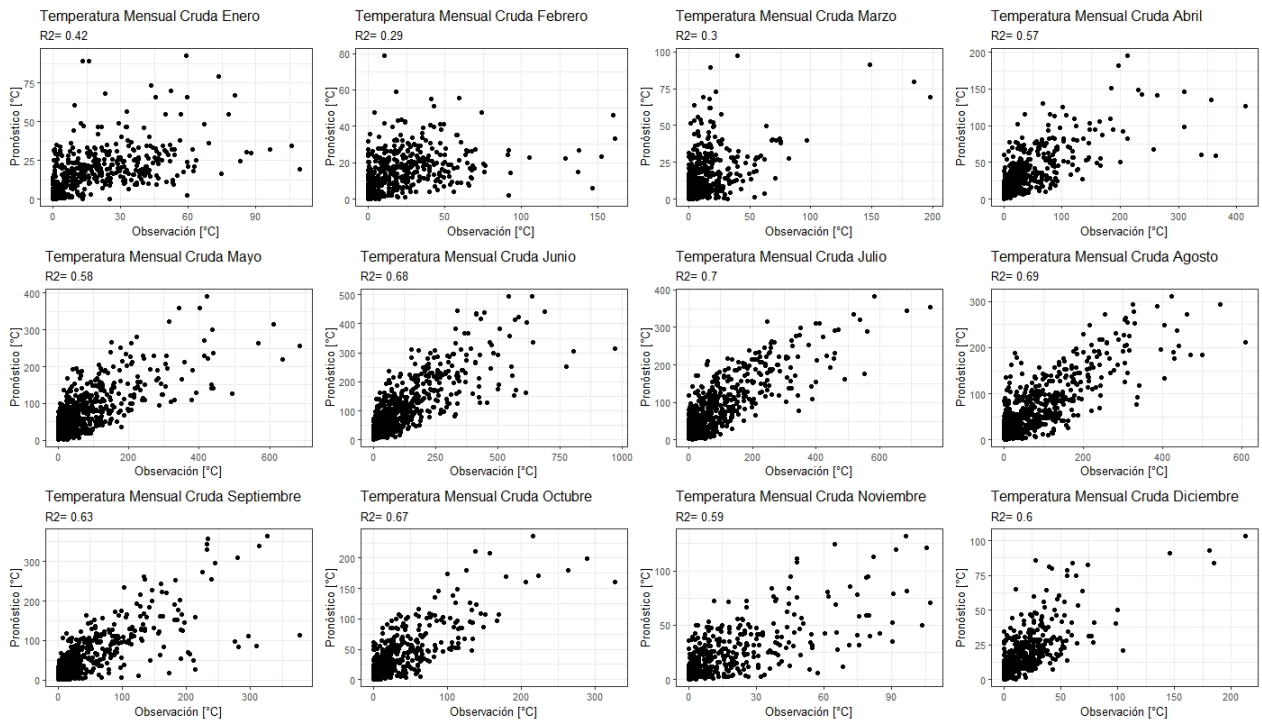


Figura B.1: Gráficos de dispersión de los pronósticos mensuales de precipitación de todas las celdas en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjunto de los pronósticos del primer mes de adelanto.

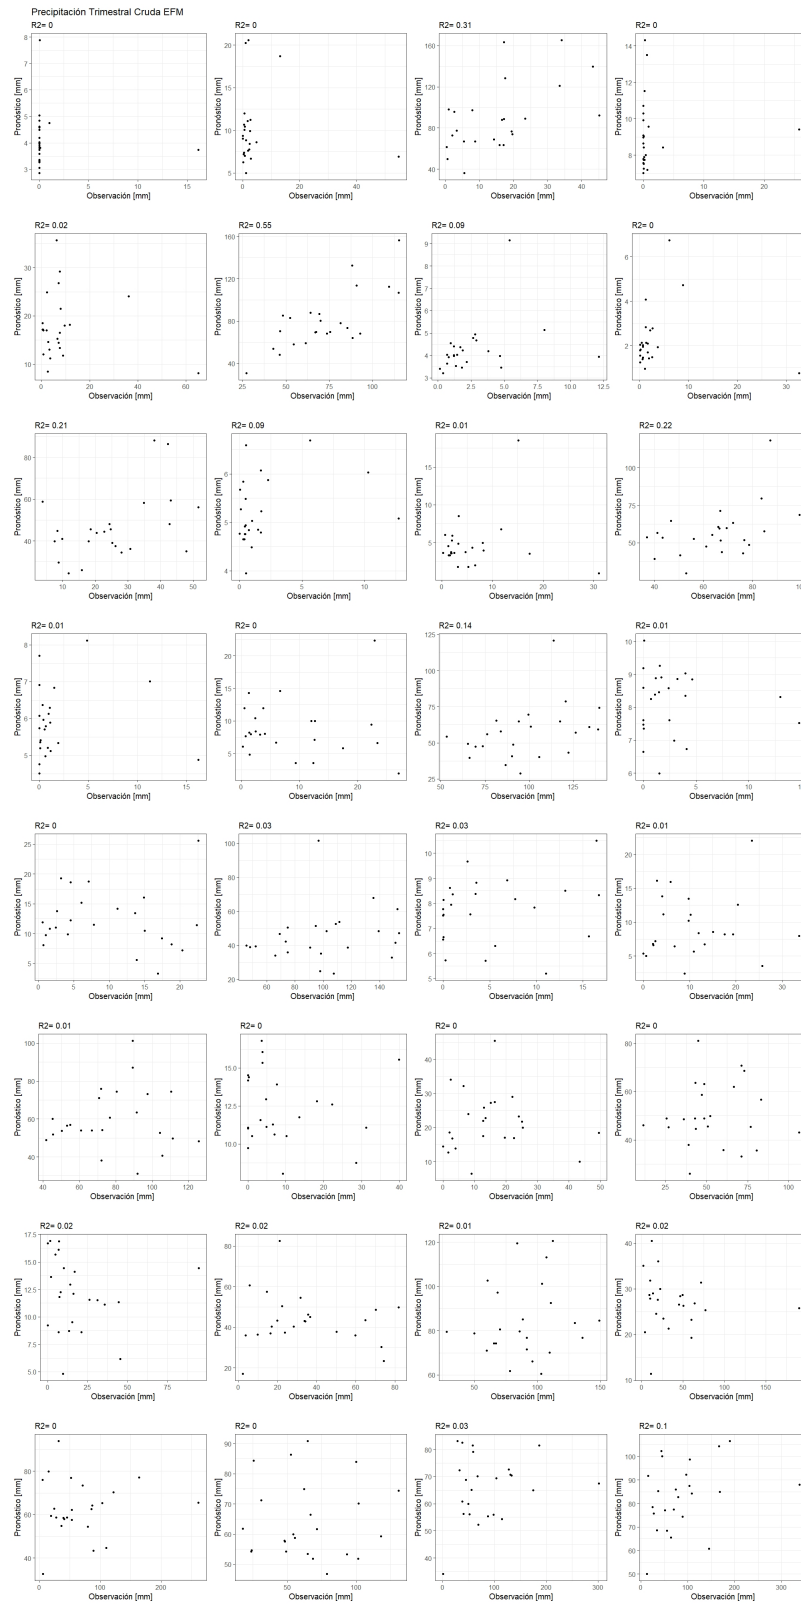


Figura B.2: Gráficos de dispersión del pronóstico crudo de precipitación del trimestre EFM, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.

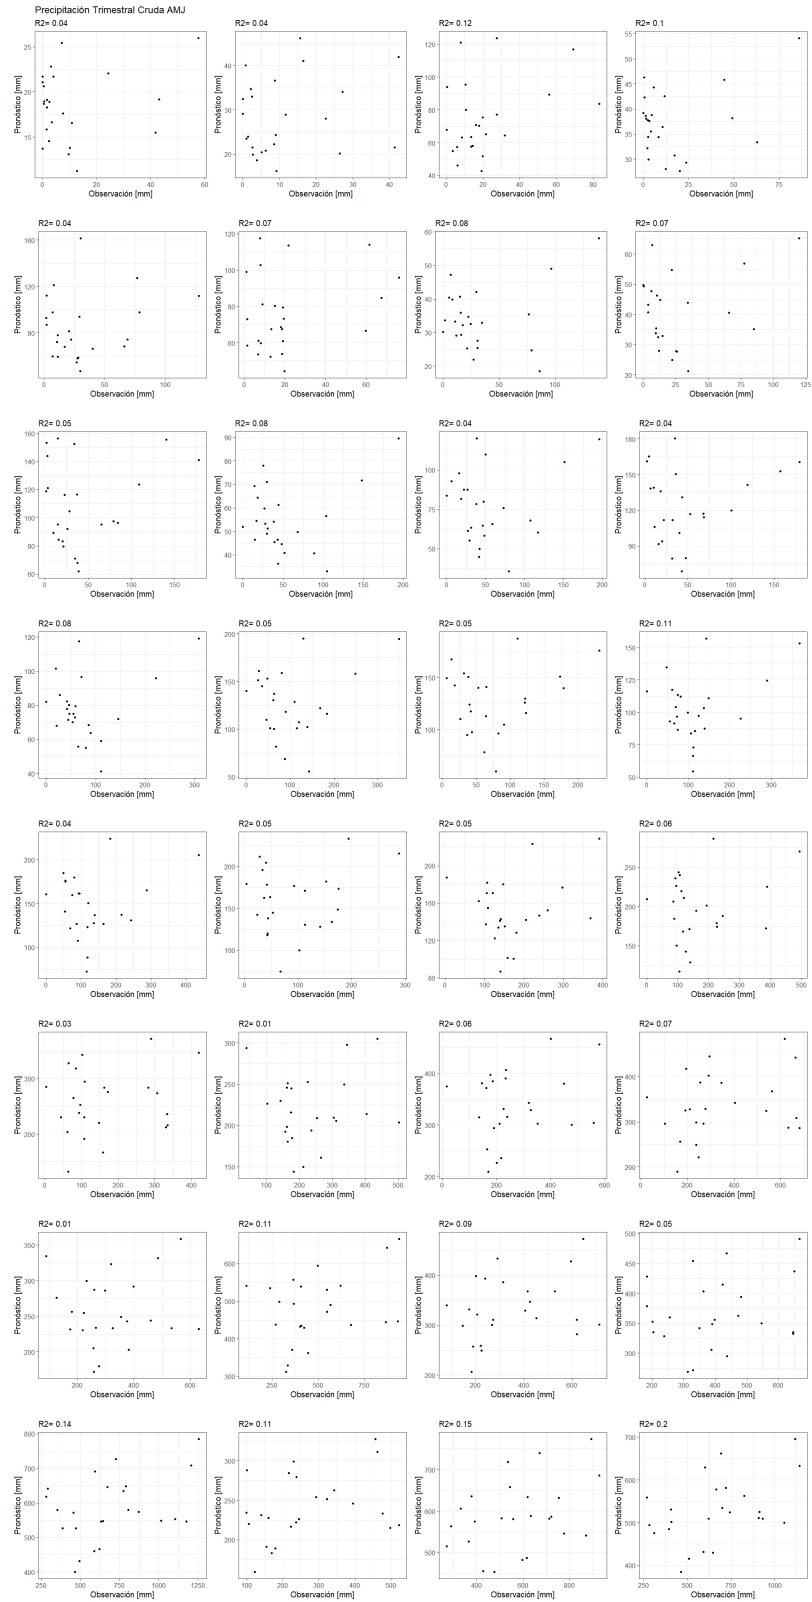


Figura B.3: Gráficos de dispersión del pronóstico crudo de precipitación del trimestre AMJ, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.

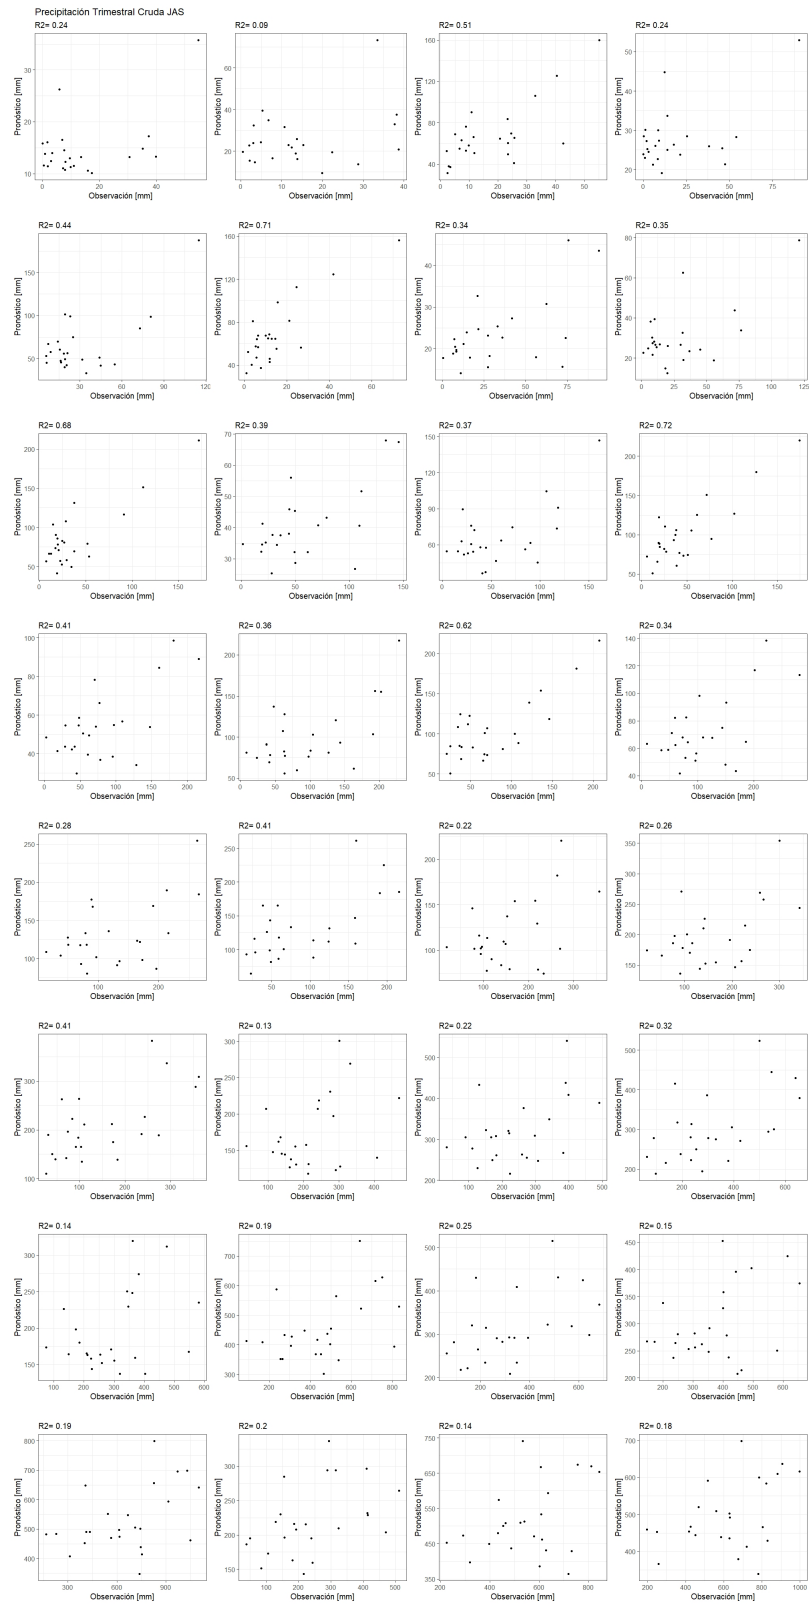


Figura B.4: Gráficos de dispersión del pronóstico crudo de precipitación del trimestre JAS, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.

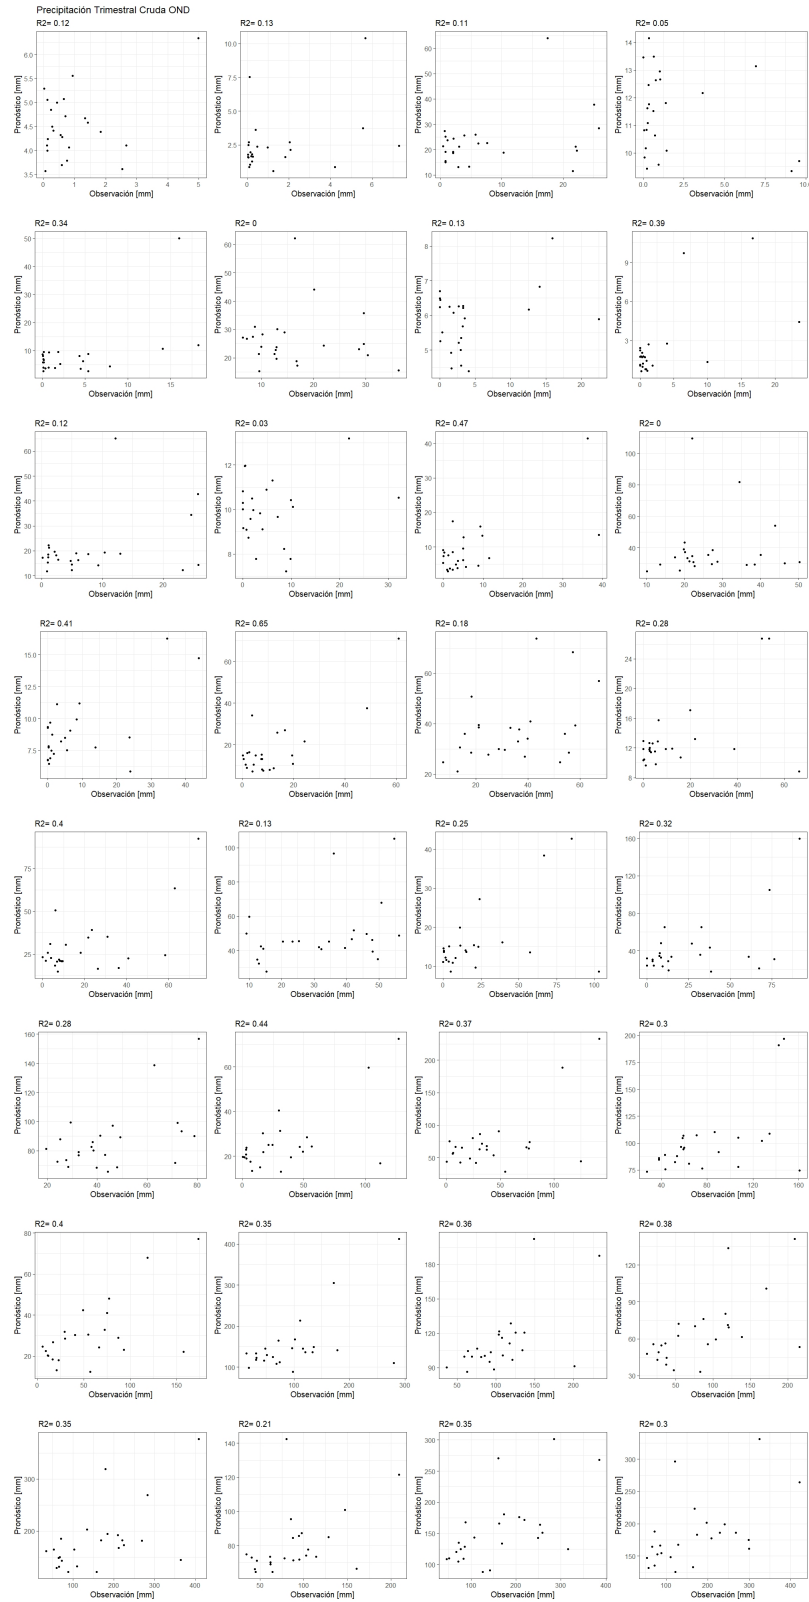


Figura B.5: Gráficos de dispersión del pronóstico crudo de precipitación del trimestre OND, para cada celda en el periodo 1993-2016. Cada punto corresponde a una observación y al promedio de los miembros del conjuntos de los pronósticos.